



**Amaro Fernando
Freitas de Caldas**

**Proposta de uma solução SCADA para a
Manutenção Preditiva**

**Proposal of a SCADA solution for Predictive
Maintenance**



**Amaro Fernando
Freitas de Caldas**

**Proposta de uma solução SCADA para a
Manutenção Preditiva**

Dissertação apresentada à Universidade de Aveiro para cumprimento dos requisitos necessários à obtenção do grau de Mestre em Engenharia Mecânica, realizada sob a orientação científica José Paulo Santos, Professor Auxiliar do Departamento de Engenharia Mecânica da Universidade de Aveiro.

o júri / the jury

presidente / president

Professor Doutor António Manuel de Bastos Pereira

Professor auxiliar da Universidade de Aveiro

vogais / examiners committee

Professor Doutor Francisco José de Oliveira Restivo

Professor associado com agregação da Universidade Católica Portuguesa (arguente)

Professor Doutor José Paulo Oliveira Santos

Professor auxiliar da Universidade de Aveiro (orientador)

agradecimentos /
acknowledgements

Agradeço a todas as pessoas que direta ou indiretamente tornaram possível a realização deste trabalho e me ajudaram a dar um passo importante na caminhada da minha formação profissional e pessoal.

Agradeço ao meu orientador, Prof. Dr. José Paulo Santos pela sua disponibilidade e ajuda sempre que foi necessário, contribuindo para o sucesso deste trabalho.

Não podia também deixar de agradecer em especial à minha família, amigos e colegas de curso, aqueles que sempre estiveram presentes e que me apoiaram incondicionalmente ao longo destes anos.

Palavras-Chave

Manutenção, Preditiva, SCADA, PLC, Redes Neurais, Algoritmos, Base de dados, Matlab

Resumo

Nos dias de hoje, a manutenção ocupa uma importante função estratégica nas organizações, dado que os custos de produção constituem um fator relevante para a produtividade e competitividade das organizações. Assim, é essencial que a manutenção apresente uma vertente mais científica e organizada, no sentido de agilizar intervenções e atingir condições físicas que permitam o melhor desempenho do equipamento, entre outras metodologias, para que resultem na máxima eficiência do processo. A manutenção preditiva representa um novo patamar na evolução da manutenção, permitindo a previsão de uma potencial falha antes da mesma acontecer, podendo assim evitar o agravamento da condição do equipamento e intervir prematuramente.

O principal objetivo da presente dissertação consiste no desenvolvimento de toda uma solução capaz de prever o agravamento de determinados parâmetros a serem monitorizados no equipamento, baseando-se na análise de séries temporais e na tecnologia de redes neurais artificiais (RNA).

keywords

Maintenance, Predictive, SCADA, PLC, Neural Network, Algorithms, Data Base, Matlab

Abstract

Nowadays, maintenance occupies an important strategic role in organizations, once production costs are an important factor for the productivity and competitiveness of organizations. In this way it is essential that maintaining show a scientific and organized side, in order to streamline operations and achieve physical conditions that allow the best equipment performance, among other methods, to result in maximum process efficiency. Predictive maintenance is a new stage in the evolution of maintenance, allowing the prediction of a potential failure before it happens, allowing to avoid the worsening of the condition of the equipment and intervene prematurely. The main objective of this dissertation is the development of an entire solution that can predict the worsening of certain parameters to be monitored in the equipment, based on time series analysis and artificial neural networks technology (RNA).

Conteúdo

1	Introdução	1
1.1	Objetivos	1
1.2	Importância do Tema em Estudo	2
1.3	Organização da Dissertação	3
2	Revisão do Estado da Arte	5
2.1	Conceitos de Manutenção	5
2.1.1	Evolução da manutenção ao longo da história	6
2.1.2	Novas abordagens e principais barreiras na gestão da manutenção	7
2.1.3	Política/definição de Manutenção	9
2.1.3.1	Corretiva	10
2.1.3.2	Preventiva	10
2.2	Manutenção Preditiva	11
2.2.1	Análise de Vibrações	12
2.2.2	Análise Térmica	14
2.2.3	Análise Elétrica	15
2.2.4	Equipamentos utilizados para análise	18
2.3	Soluções Existentes de Apoio à Manutenção	19
2.3.1	Simulação	19
2.3.2	Software SCADA	20
2.3.3	CMMS	21
2.3.4	Software SCADA e CMMS	23
2.4	Execução de um Programa de Manutenção	24
3	Metodologias Preditivas	27
3.1	Séries Temporais	27
3.1.1	Caraterísticas típicas de Séries Temporais	28
3.1.2	Modelos autorregressivos(RA)	29
3.1.3	Modelos de Média Móvel (MA)	29
3.1.4	Modelos autorregressivos e de média móvel (ARMA)	30

3.1.5	Modelos autorregressivos integrados de média móvel (ARIMA)	30
3.1.6	Modelos de amortecimento exponencial	30
3.1.6.1	Amortecimento exponencial	31
3.1.6.2	Método de Holt e Holt-Winters	31
3.2	Métodos com Inteligência Artificial	32
3.2.1	Árvores de decisão	32
3.2.1.1	Algoritmo ID3	33
3.2.2	Redes Neurais	34
3.2.2.1	Componentes e Arquitetura de uma Rede Neuronal	36
3.2.2.2	O modelo <i>Perceptron</i> de Multi-Camadas	37
3.2.2.3	Processo de aprendizagem e algoritmos de treino	38
3.2.2.4	Algoritmos de <i>Back-Propagation</i>	39
3.2.2.5	Algoritmos baseados em <i>back-propagation</i>	41
4	Solução Proposta e Implementação	43
4.1	Solução Proposta	43
4.1.1	Arquitetura do protótipo	43
4.1.2	Escolha da solução	45
4.2	Implementação	46
4.2.1	Hardware	46
4.2.1.1	Aquisição de Temperatura	47
4.2.1.2	Analisador de Potência	49
4.2.1.3	Motor Elétrico	50
4.2.1.4	PLC	52
4.2.2	Desenvolvimento e configuração de software	55
4.2.2.1	Programação PLC	55
4.2.2.2	Configuração Janitza UMG604	57
4.2.2.3	MatLab	58
4.2.2.4	Movicon	60
4.2.2.5	MySQL	62
5	Análise de resultados e considerações finais	65
5.1	Análise de Resultados	65
5.1.1	Metodologia de Análise	65
5.1.2	Método NARX	70
5.1.2.1	Previsão de uma Iteração	71
5.1.2.2	Previsão de várias iterações	72
5.1.3	Método NAR	73
5.1.3.1	Previsão de uma iteração	74

5.1.3.2	Previsão Multi-Iteração	75
5.1.4	Tempo de processamento	76
5.2	Conclusões e propostas de trabalho futuro	77
Bibliografia		80
A Apêndice		87
A.1	Outros equipamentos de análise para manutenção	87
A.2	Alimentação do autômato	88
A.3	Programação Ladder Autômato	89
A.4	Tempos de Processamento	90

Lista de Figuras

2.1	Evolução do conceito de manutenção ao longo do tempo.	7
2.2	Níveis de redes industriais.	9
2.3	Políticas de Manutenção	10
2.4	Tipica configuração de um equipamento.	13
2.5	Imagens captadas por uma câmara termográfica	15
2.6	Esquema com todos os tipos de motores elétricos.	16
2.7	Exemplo de equipamentos portáteis utilizados para cada tipo de análise. . . .	18
2.8	Exemplo de equipamentos fixos utilizados para cada tipo de análise.	19
2.9	Interface <i>software Arena</i>	20
2.10	Plataforma SCADA utilizando o <i>Movicon 11</i> e o <i>Lookout</i>	21
2.11	Exemplo de uma interface de <i>software</i> CMMS (MA CMMS software).	22
2.12	Esquema de Funcionamento SCADA e CMMS.	23
2.13	Esquema com o ciclo da Manutenção preditiva.	24
2.14	Plano de manutenção exemplo	26
3.1	Tendência de uma série.	28
3.2	Tabela meramente ilustrativa, valores não provados.	33
3.3	Gráfico com relação entropia/erro.	34
3.4	Categorização dos diferente tipos de Redes Neurais.	35
3.5	Processo de Modelação das Redes Neurais.	36
3.6	Modelo matemático do neurónio proposto por McCulloch e Pitts.	36
3.7	Rede Neuronal Multicamada (MLP).	37
3.8	Procedimento para ajuste dos parâmetros da RNA	38
3.9	Rede Neuronal com <i>Back Propagation</i>	40
4.1	Representação da posição da solução proposta.	43
4.2	Arquitetura Geral da Solução Proposta.	45
4.3	Primeiros testes para o desenvolvimento e escolha da solução.	46
4.4	Demonstração do hardware da solução.	47
4.5	Esquema elétrico produzido no software EPLAN.	47
4.6	Sensores de temperatura utilizados.	48

4.7	Sensor LM 35 e PT1000 com respectiva implementação.	48
4.8	Implementação do Sensor de PT1000	49
4.9	Configuração para analisar a alimentação do motor	50
4.10	Chapa de características do motor elétrico.	51
4.11	Valores reais de corrente e voltagem registados.	51
4.12	Relação Potência e Fator de Potência.	52
4.13	PLC Vipa Slio 015.	52
4.14	Estrutura autômato.	53
4.15	Esquema ligação autômato/sensor de temperatura	54
4.16	Fluxograma do software implementado na solução proposta.	55
4.17	Fluxograma e função de conversão dos dados recebido pelo sensor.	56
4.18	Configuração de alguns parâmetros.	57
4.19	Método NARX e NAR.	58
4.20	Fluxograma da aplicação das Redes Neurais.	59
4.21	Interface aplicação.	60
4.22	Grafismo apresentado pela aplicação SCADA.	62
4.23	Janela das base de Dados.	63
5.1	Série temporal da evolução da temperatura	66
5.2	Séries temporais do valor de inputs em cada caso de estudo.	67
5.3	Séries temporais do valor de inputs em cada caso de estudo.	68
5.4	Relação entre parâmetros.	69
5.5	Relação entre parâmetros.	70
5.6	Previsão com o parâmetro externo mais influente	71
5.7	Resultado como todos os parâmetros de entrada	72
5.8	Previsão multi-passo uma entrada	73
5.9	Previsão de vários passos à frente e com várias entradas	73
5.10	Previsão de uma iteração à frente.	74
5.11	Previsão Multi-Iterações.	75
5.12	Tempos totais de processamento	76
5.13	Relação tempo de simulação com tempo de treino.	77
A.1	Analisador de óleo da SKF.	87
A.2	Estroboscópio TKRS10 da SKF.	88
A.3	Conversor utilizado.	88
A.4	Módulo de alimentação do autômato Slio	88
A.5	Parte do OB1.	89
A.6	Ativação de saídas a partir do <i>Movicon</i>	90

Lista de Tabelas

1.1	Benefícios da manutenção preditiva	2
2.1	Tabela de Gravidade consoante a valor de vibração registado.	14
2.2	Legenda da classes vibração.	14
3.1	Tabela meramente ilustrativa, valores não provados.	33
4.1	Legenda da figura autómato.	53
4.2	Legenda da figura ligação.	55
A.1	Tempos totais de processamento.	90
A.2	Tempo de processamento no treino da rede.	90
A.3	Relação do tempo de processamento treino/total.	90

Capítulo 1

Introdução

O tema desta tese surge do interesse pessoal pela área da automação e manutenção industrial e ainda pelo facto de poder contribuir para a evolução nos processos produtivos, nomeadamente na área da manutenção.

Na economia globalizada dos dias de hoje, a sobrevivência das organizações depende da sua capacidade de inovar, da atualização constante e da procura incessante no otimização de soluções.

Nas ultimas décadas, este domínio tem sofrido mudanças significativas, possivelmente mais do que qualquer outra área de gestão[1]. Estas mudanças devem-se ao aumento da variedade de aspetos físicos (equipamentos, sistemas e estruturas) e da crescente preocupação do seu impacto no ambiente, segurança, mais valias económicas e qualidade dos produtos. Nesta perspetiva, os gestores procuram adotar novos métodos de manutenção, com o objetivo de evitar o disfuncionamento dos equipamentos e paragens técnicas que poderão trazer consequências negativamente relevantes para quem faz o planeamento da produção[2], uma vez que podem originar incumprimentos para com o cliente, diminuição da qualidade do produto e aumento do custo de produção.

1.1 Objetivos

Este estudo pretende ser uma mais valia para a gestão eficiente da manutenção de linhas de produção fabril numa empresa.

Neste contexto, procura-se encontrar um sistema que reduza os impactos da manutenção, na segurança, tesouraria e na qualidade dos produtos. Para o efeito, analisou-se a literatura existente, realizou-se uma análise comparativa de várias tecnologias comuns e emergentes, com o intuito de propor uma solução a sua implementação e análise de resultados.

A solução criada deverá ter como base uma aplicação SCADA que irá ser responsável pelo supervisionamento, a aquisição e armazenamento dos dados registados pelo *hardware*;

este método de obtenção de dados terá de ser criteriosamente selecionado e o que melhor se adequa a este tipo de manutenção, conciliando a utilização de algoritmos capazes de prever a evolução dos parâmetros adquiridos e permita alertar a equipa de manutenção, caso se antevejam anomalias.

1.2 Importância do Tema em Estudo

A falta de manutenção regular dos equipamentos pode originar avarias com consequências potencialmente perigosas, tais como acidentes (cintas transportadoras, estruturas de elevação, guinchos com defeito, etc.), diminuir a segurança dos trabalhadores e eventualmente poderá ter impactos na saúde.

Uma manutenção eficiente deve permitir que todos os equipamentos ou materiais proporcionem altos rendimentos, que atinjam excelência na qualidade dos produtos e que reduzam o tempo de paragem por avaria.

Mais concretamente, a manutenção preditiva representa um conceito moderno de manutenção e aparece como a forma mais eficaz de programar intervenções nos equipamentos, efetuando o controlo da sua condição, determinando o momento mais oportuno para efetuar a sua manutenção e prever a falha antes de a mesma ocorrer, evitando assim consequências graves para o equipamento.

Este tipo de manutenção pode proporcionar benefícios significativos [3], desde logo na redução de custos, no incremento de produtividade, no aumento do tempo de vida dos equipamentos, entre outros parâmetros, conforme a tabela abaixo 1.1.

Tabela 1.1: Benefícios da manutenção preditiva.[3]

Benefício	Percentagem
Redução dos custos de manutenção	50% a 80%
Redução de falhas nas máquinas	50% a 60%
Redução de existências de peças suplentes	20% a 30%
Redução de horas extra para a manutenção	20% a 50%
Redução de tempo das máquinas paradas	50% a 80%
Aumento do tempo de vida	20% a 40%
Aumento da produtividade	20% a 30%
Aumento dos lucros	25% a 60%

A manutenção preditiva não é incompatível com os procedimentos dos programas tradicionais preventivos e corretivos, porém pode reduzir o número de falhas inesperadas, bem como fornecer uma ferramenta de programação mais confiável, para tarefas rotineiras de manutenção preventiva.

1.3 Organização da Dissertação

Esta dissertação será dividida em cinco capítulos. O presente capítulo inicia o documento e o subsequente é dedicado a uma revisão do Estado da Arte. Este segundo capítulo justifica-se pelo facto de fazer referência a conhecimentos prévios, evitando, deste modo, perda de tempo com investigações supérfluas. Além disso, auxilia na melhoria e desenvolvimento de novos postulados, conceitos e paradigmas.

O terceiro capítulo é uma espécie de estado da arte, não do tema principal - a manutenção -, mas relativamente às metodologias preditivas, com principal enfoque na utilização de redes neuronais e na previsão de séries temporais.

No quarto, é descrita a solução proposta e a sua implementação em laboratório, referindo todos os equipamentos seleccionados e a sua construção, bem como o *software* utilizado.

Finalmente, no ultimo capítulo é discutido o desempenho da solução proposta, terminando com considerações finais.

Capítulo 2

Revisão do Estado da Arte

Este capítulo é de extrema relevância para o desenvolvimento da dissertação, dado que é fundamental refletir sobre conceitos adquiridos de forma a promover a continuidade no desenvolvimento científico, auxiliando na melhoria e desenvolvimento de novos produtos, conceitos e paradigmas.

O presente capítulo divide-se em quatro subcapítulos que abordam sucessivamente, conceitos de manutenção, manutenção preditiva propriamente dita, soluções existentes e execução de um programa.

2.1 Conceitos de Manutenção

Considera-se que a manutenção possa representar 15 a 40 por cento do custo de produção [4], em alguns casos, como por exemplo nas indústrias pesadas, onde é exigido mais esforço aos equipamentos, pode até ser superior a 60 por cento [5]; com a automação, da produção os gestores começam a valorizar esta área, nomeadamente o controlo de custos.

A manutenção tem como principais propósitos reduzir os efeitos adversos da paragem dos equipamentos e maximizar a sua disponibilidade ao mais baixo custo [6]. Nos dias de hoje, com concorrência cada vez mais acérrima, um bom plano de gestão da manutenção torna-se imprescindível, porém ainda existe uma quantidade significativa de empresas em que a manutenção é frequentemente vista como um mal necessário, desvalorizada pelos gestores que não investem no eficaz controlo de custos. Felizmente, surgem também empresas que reconhecem que uma boa manutenção é parte essencial da operacionalização e que uma estratégia devidamente orientada contribui significativamente para adicionar valor ao processo produtivo [7].

Atualmente assiste-se a um processo de mudança de mentalidades relativamente à forma como a manutenção é percecionada, atribuindo-se-lhe um papel de maior relevância pelo que, nesta secção, faz todo o sentido fazer o seu enquadramento histórico e apresentar novas abordagens e políticas de manutenção.

2.1.1 Evolução da manutenção ao longo da história

No passado, a manutenção era tão só entendida como um trabalho de reparação. As máquinas funcionavam até pararem, não existindo nenhum procedimento que pudesse prever as falhas. A aplicação do conceito de manutenção surge mais intensivamente nos inícios dos anos 30, através das unidades militares, que tinham como objetivo manter todas as unidades de combate, e em geral todo o equipamento, num nível aceitável de funcionamento.

Até ao final dos anos quarenta, a Manutenção Industrial encontrava-se na fase de desenvolvimento, limitando-se apenas à reparação de avarias ou à substituição das peças danificadas. Este período é referido como a Fase 1 da Evolução da Manutenção – Reparar a Avaria.[1]

Com o aparecimento das linhas de produção, as empresas começaram por atribuir mais protagonismo à manutenção dos equipamentos; em 1950, o conceito de manutenção preventiva começava a ser aplicado e a manutenção baseada no tempo (*time based maintenance*) era introduzida [8]. A TBM é baseada numa monitorização constante, que representa o aumento da probabilidade de falha dos equipamentos depois de um certo período de operações.

Nasce então a Engenharia de Manutenção que vai criar processos científicos de manutenção preventiva, cuja preocupação dominante é a constante disponibilidade dos equipamentos. Este período é classificado como a Fase 2 da Evolução da Manutenção – Evitar a Avaria.[1] Nos anos 60, com a globalização dos mercados, faz-se sentir a necessidade de mais eficiência na produção. Recorre-se, por isso, cada vez mais, a dois ou três turnos de trabalho, daí o apelo crescente à manutenção, para que aumente a disponibilidade dos equipamentos. Sendo as operações contínuas, a manutenção é obrigada a definir estratégias para garantir que as máquinas trabalhem dentro de um determinado padrão de eficiência.

Nos anos 70, novos conceitos estratégicos foram surgindo e a manutenção baseada na confiabilidade (*condition based maintenance*) foi proposta para diagnóstico técnico das máquinas. No entanto, verificou-se que este método, em algumas situações, não era o melhor, especialmente numa relação de custo/eficiência. Por isso mesmo, a meio da década de 80, a importância da seleção da melhor estratégia foi desenvolvida em várias áreas. A manutenção centrada na reabilitação (*Reability Centered Maintenance*) e inspeção baseada no risco (*Risk based Inspektion*) ou manutenção baseada no risco (*Risk Based Maintenance*) são os métodos mais conhecidos para este objetivo [9]. Este período é classificado como a Fase 3 da Evolução da Manutenção - Antever a Avaria [1].

Na figura 2.1 são representadas, cronologicamente, as principais fases da evolução do conceito.




Figura 2.1: Evolução do conceito de manutenção ao longo do tempo [1].

2.1.2 Novas abordagens e principais barreiras na gestão da manutenção

No presente século, assiste-se a uma nova fase de mudança no conceito de manutenção com as novas tecnologias cada vez mais presentes na indústria que tornam mais eficientes as monitorizações dos equipamentos, mas simultaneamente tornam o processo mais complexo.

Por um lado, soluções de avaliação de risco fazem com que se abandonem progressivamente as manutenções tradicionais e baseadas no tempo, para adotar estratégias baseadas na condição ou estado dos componentes e o risco associado. Por outro lado, o mercado torna-se mais exigente quanto aos requisitos da qualidade. Como consequência, os equipamentos tornam-se complexos e a manutenção é naturalmente afetada, sendo necessário procurar novas estratégias. Novos conceitos tais como: manutenção baseada na condição (*condition-based maintenance* (CBM)), inspeção baseada no risco (*risk-based inspection* (RBI)), gestão do tempo de vida baseado no risco (*risk-based life management* (RBLM)), são estratégias que surgem em força na indústria [10].

A manutenção baseada na condição é uma variante da Manutenção Preditiva, trata-se de um método usado para reduzir as incertezas das atividades de manutenção e as medidas são aplicadas de acordo com a condição em que o equipamento se encontra.

A manutenção baseada no risco tenta responder a 5 questões importantes relacionadas com a integridade e falha de operação do sistema [2]:

- o que pode provocar a falha do sistema?
- como pode afetar o sistema?
- quais as consequências, caso o sistema falhe?
- com que probabilidade acontece?
- Durante a manutenção e inspeção, que componentes são mais passíveis de causar falhas?

Com o planeamento baseado no risco, espera-se obter uma manutenção com um custo mais eficiente, o que minimiza as consequências relacionadas com a segurança, economia e ambiente.

Como podemos ver, as atividades de manutenção tendem para um processo complexo, aliando diversas áreas, tais como a informática, a eletrónica, os sistemas mecânicos, a automação e a gestão.

Um outro fator que contribui para a complexidade atual do processo de manutenção é a subcontratação dos serviços, cada vez mais frequente. Existem organizações em todo mundo que procuram novas abordagens para manter ou desenvolver a vantagem competitiva, o que complica o processo, já que antes de tomar medidas no sentido da subcontratação deve-se desenvolver um plano global. Este plano deve seguir um determinado protocolo - nomear os gestores e outros intervenientes na atividade, avaliar se a subcontratação é imprescindível ou se existem alternativas, estruturar a proposta de subcontratação, quer em termos legais, quer operacionais, entre outros. Com o plano executado, resta ainda avaliar a prontidão da empresa a subcontratar [11].

Atualmente, das principais barreiras existentes na manutenção, destacam-se [12]:

- escolha das práticas que conduzam a um desempenho superior (benchmarking);
- falta de comunicação e informação;
- falta na medição e controlo dos parâmetros de performance, rácio de qualidade e a razão da disponibilidade do sistema;
- aumento da complexidade dos sistemas;
- insistência de uma proposta e plano estratégico e a sua implementação;
- falta de preocupações com a segurança e saúde.

Com os problemas atuais do mercado, com clientes mais exigentes e com a procura de uma vasta gama de produtos, surgem os sistemas flexíveis de produção (FMS), cada vez mais frequentes, que tornam o processo bastante automatizado e flexível e que são capazes de tratar uma variedade de produtos de volume médio e admitir rápidas alterações no processo, alcançando alta produtividade sem perder a qualidade dos produtos [13].

A arquitetura mais usual neste tipo de produção aparece representada na figura 2.2. A organização deste sistema divide-se em 5 níveis com as respetivas funções em que, para cada nível, usa-se os seguintes softwares:

- Nível 4 - Software ERP (Primavera e PHC);
- Nível 3 - Software MES (*Manufacturing Execution System*) e PIMS (Plant Information Management System);
- Nível 2 - Software SCADA;
- Nível 1 - PLC (software de programação de PLC);

- Nível 0 - Sensores indutivos, HMI, consolas;




Figura 2.2: Níveis de redes industriais.

2.1.3 Política/definição de Manutenção

Feito o enquadramento histórico (para se perceber a manutenção preditiva e o seu programa de gestão) deve-se considerar, em primeiro lugar, as técnicas tradicionalmente adotadas. Tipicamente, na indústria, são aplicados dois tipos de manutenção [9], uma diretamente ligada à prevenção e à antecipação de falhas, denominada manutenção preventiva/preditiva, e a outra direcionada para a correção de falhas - a manutenção corretiva. Muitas das vezes, na literatura, a manutenção preditiva é associada à preventiva sendo até, em alguns casos, considerado o mesmo programa (como podemos ver pela figura 2.3 em que autor aborda as duas temáticas como uma só) e num outro exemplo [14] a manutenção preditiva é considerada uma parte da manutenção preventiva. Nesta subsecção, será considerada a manutenção preditiva como fazendo parte da preventiva e no subcapítulo seguinte (capítulo 2.2) far-se-á a distinção entre manutenção preventiva e manutenção preditiva propriamente dita.

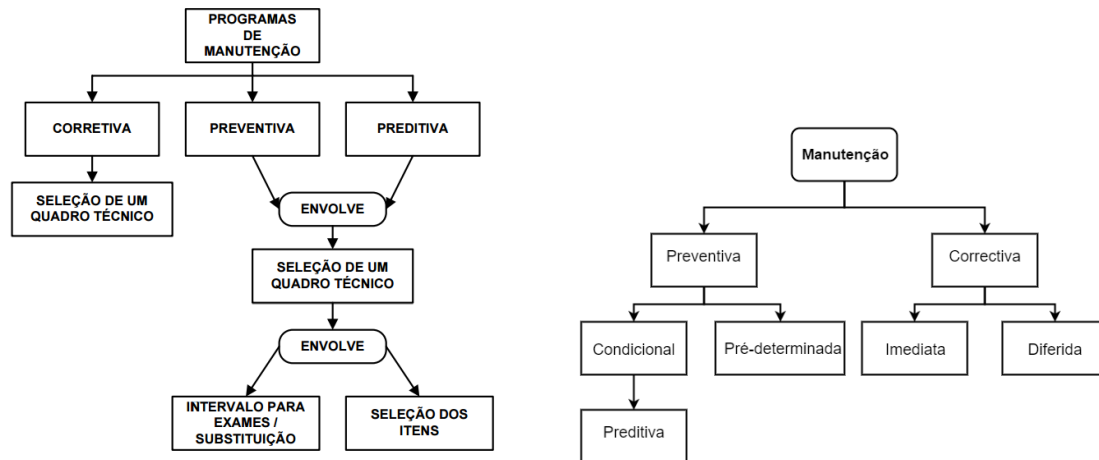


Figura 2.3: Políticas de Manutenção adaptado de [9] e [14], respetivamente.

2.1.3.1 Corretiva

Este tipo de manutenção, que não é planeada, acontece quando o equipamento tenha cessado ou diminuído a capacidade do equipamento de exercer as funções para as quais foi projetado e tem como objetivo a localização, correção, restauração, recuperação e reparação de anomalias ou defeitos. É uma forma de manutenção que exige uma estrutura capaz de responder a todos os tipos de falhas que possam acontecer, o que, consequentemente, força a que o departamento de manutenção mantenha uma extenso inventário de peças para substituição ou até mesmo máquinas extra para reposição. Uma alternativa pode passar por um contacto permanente com os fornecedores de forma a responderem às necessidades o mais rápido possível. No entanto, sendo esta uma possibilidade, aumentaria significativamente os custos de reparação, já que pedir peças ao fornecedor no momento após falha representa um aumento no custo três vezes superior, comparativamente à mesma intervenção agendada ou feita por prevenção [5].

2.1.3.2 Preventiva

Este método permite uma redução dos imponderáveis que originam graves problemas para os gestores de produção, com atrasos significativos no cronograma de fabricação, indisponibilidade da máquina e elevação de custos. Na literatura, a manutenção preventiva é, por vezes, assumida como manutenção preditiva, todavia, estas devem ser tratadas de forma diferente.

Para Norberto Moro[15], a manutenção tem grande relevância para atingir os objetivos principais das empresas, tais como:

- Redução de custos
- Qualidade do produto

- Aumento da produção
- Efeitos no meio ambiente
- Aumento da vida útil dos equipamentos
- Redução dos acidentes de trabalho

Ao ser posta em prática, esta metodologia rege-se por um planeamento periódico executado previamente. Esta periodicidade denomina-se MTBF (do inglês, *Mean Time Between Failures*), o que traduzido corresponde ao "tempo estimado entre falhas". Conhecendo o valor deste tempo, é possível intervir nos equipamentos, prevenindo assim a ocorrência de falha. Apesar das vantagens que este método apresenta, quando aplicado isoladamente, demonstra algumas limitações, apresenta custos elevados e, em muitos casos, torna-se um processo ineficiente [16].

Esta forma de realizar a manutenção pode ser sistemática, ou seja, como os equipamentos apresentam potencialmente uma taxa de falhas constantes, procede-se à substituição de componentes ou a revisões, em intervalos de tempo definidos, mesmo que o equipamento se encontre totalmente funcional. Esta abordagem é frequentemente aplicada em máquinas cujas avarias provocam paragens por tempo significativo ou quando colocam em causa a segurança dos indivíduos. Uma outra abordagem é a manutenção condicionada; na realidade trata-se de uma outra versão da manutenção preditiva. Por vezes, a manutenção preditiva é abordada isoladamente, outras vezes, como uma variante da manutenção preventiva. Esta forma de manutenção é abordada com detalhe no subcapítulo seguinte (capítulo 2.2).

2.2 Manutenção Preditiva

Segundo Borwn M.[17], a manutenção preditiva é definida como uma abordagem que compara a tendência das medições dos parâmetros físicos analisados (vibração, ruído, temperatura) com os limites estabelecidos para esses parâmetros, de forma a detetar, analisar e corrigir problemas precocemente. Já para Lima e Sales[18], a adoção da manutenção preditiva explora os dispositivos físicos para controlo e manutenção da qualidade do produto final que é gerado no equipamento.

Também Faria, Costa e Olivas [19] retratam-na como uma manutenção pró-ativa focada em determinar as causas da falha da máquina, utilizando ferramentas para que a mesma não ocorra. Neste tipo de programa, considera-se esta antecipação fundamental, uma vez que uma manutenção pró-ativa visa, por exemplo, detetar a contaminação de fluidos lubrificantes utilizados nas máquinas, diminuindo o número de substituições preventivas.

Posto isto, a manutenção preditiva é um programa que indica as condições reais de funcionamento das máquinas com base em dados que informam sobre o seu desgaste ou processo

de degradação. É uma metodologia que prediz o tempo de vida útil dos componente das máquinas e equipamentos, bem como as condições para que esse tempo de vida seja aumentado.

Existem inúmeras técnicas para este tipo de manutenção tais como[5] :

- Monitorização das vibrações
- Emissão acústica
- Análise a óleos
- Análise às partículas libertadas pelos equipamentos
- Inspeções visuais
- Termografia
- Ultrassons
- Análise elétrica

Como resultado da utilização destas técnicas, maximizam-se os intervalos entre reparações e o rendimento do processo produtivo, visto que os equipamentos e as instalações estão disponíveis o maior tempo possível. É como tal cada vez mais importante o estudo em diversas áreas, desde a aquisição de dados até à sua interpretação, para melhorar a implementação destas técnicas, quer pelos próprios fabricantes, quer pelos clientes, a quando da aquisição de novos equipamentos [20].

Apesar destes métodos e formas de análise, é preciso ter em conta que existem casos para os quais programas com este tipo de manutenção não são capazes de demonstrar benefícios tangíveis para a organização. Consequentemente, é essencial a investigação e desenvolvimento neste domínio dado que é possível reduzir estes casos[21] .

As principais barreiras verificam-se na necessidade de adquirir equipamentos tecnicamente sofisticados, que permitam fazer análises com o máximo de rigor possível, no entanto, são instrumentos normalmente dispendiosos que exigem mão de obra especializada.

Face a estas adversidades, na hora de aplicar, a manutenção preditiva torna-se um entrave, pois é necessário um grande investimento.

Motivo pelo qual, se procura o desenvolvimento de uma solução de fácil implementação e utilização para que, sem investimentos significativos, se consiga usufruir dos benefícios deste tipo de manutenção.

2.2.1 Análise de Vibrações

A análise de vibrações é usada para determinar a condição operacional ou mecânica do equipamento. Uma das principais vantagens deste tipo de análise é poder identificar problemas

que começam a surgir no equipamento, antes de este ter de parar por um agravamento da avaria [21]. Isto pode ser conseguido com uma monitorização regular das vibrações produzidas pela máquina, podendo ser continua ou por intervalos de tempo agendados.

Partes rotativas e outros componentes da maquinaria existente podem ser constituídas por estator, rotor, rolamentos, engrenagens e acoplamentos. A figura 2.4 representa a arquitetura mecânica típica de uma máquina industrial apresentando avarias comuns.




Figura 2.4: Típica configuração de um equipamento adaptado de [21].

Quando estes componentes trabalham em altas velocidades, o risco de falha é eminente. Ao ocorrerem pequenos defeitos, a vibração do equipamento sofrerá alterações, aumentando os níveis de vibração. De uma forma geral, o que leva ao aumento dos valores da vibração são uma ou mais partes desniveladas, desalinhadas, folgadas, fora da tolerância, partidas ou a reagir com uma força externa. O aumento da amplitude das vibrações em frequências particulares pode ser um indicador de problemas ou defeitos de performance do mecanismo.

Um dilema comum neste tipo de análise estará em determinar qual o nível de vibração aceitável que reflita um funcionamento saudável da máquina. É difícil definir um intervalo dentro do qual a máquina estará em funcionamento perfeito, a não ser que alguns manuais estejam disponíveis ou então que o próprio fabricante disponibilize modelos exemplificativos dos limites aceitáveis. De facto, existe um guião, ou melhor uma norma que é utilizada largamente, a ISO 2372 [21] que pode ser usada para determinar os níveis de vibração aceitáveis para várias classes de maquinaria. Portanto, para utilizar esta norma, tem de se identificar a classe da máquina em questão, para comparar os intervalos de velocidade de vibração e picos.

Tabela 2.1: Tabela de Gravidade consoante a valor de vibração registado.

Gravidade da Vibração segundo ISO 2372 (10816)						
Velocidade de vibração V_{rms}	Máquina		Classe 1	Classe 2	Classe 3	Classe 4
	in/s	mm/s				
	0,01	0,28				
	0,02	0,45				
	0,03	0,71				
	0,04	1,12				
	0,07	1,80				
	0,11	2,80				
	0,18	4,50				
	0,28	7,10				
	0,44	11,20				
	0,70	18,00				
	1,10	28,00				
	1,77	45,90				

Tabela 2.2: Legenda da tabela 2.1

Classe 1	Partes individuais de uma máquina ou motor conectado integralmente em condições de funcionamento (motores elétricos com potências abaixo dos 15kW são exemplos de máquinas para esta categoria)
Classe 2	Máquinas de tamanho médio (normalmente motores elétricos com 15-75kW)
Classe 3	Máquinas de grande porte com massas rotativas acopladas em fundações rígidas e pesadas
Classe 4	Grandes motores ou máquinas com grandes massas de rotação montadas em fundações suaves na direção medida da vibração.
Verde	Bom
Verde claro	Aceitável
Amarelo	Satisfatório
Vermelho	Inaceitável

2.2.2 Análise Térmica

A termografia tem tido uma utilidade crescente na indústria, dado que os custos associados à aquisição de um equipamento termográfico estão a reduzir. Com a evolução tecnológica este tipo de equipamento tem se tornado cada vez mais acessível.

Esta técnica de manutenção preditiva pode ser usada para monitorizar, não só equipamentos elétricos, mas também a estrutura da máquina, componentes, sistemas de equipamentos mecânicos dinâmicos e estáticos.

Com esta análise é possível detetar, em estágio inicial, processos de falha gerados por

anomalias térmicas num determinado componente sem que seja necessário interromper o funcionamento dos equipamentos, podendo classificá-las e quantificá-las.

As imagens registadas por uma câmara termográfica, figura 2.5, apresentam cores mais quentes como o amarelo e o vermelho que representam os pontos mais quentes, e cores frias como o azul e o violeta, as áreas de menor temperatura¹. Em equipamentos eléctricos, o aumento de temperatura pode estar associado a sobrecargas ou a diferença de tensão fora do normal, o que geralmente se associa a uma falha, enquanto que nos equipamentos mecânicos, a temperatura geralmente é elevada, quando o aumento de atrito é significativo, seja por mau funcionamento de rolamento, uma rótula desgastada, ou então a falta de líquido de lubrificação.

A análise térmica é um método interessante, uma vez que permite uma análise sem contacto, o que facilita a monitorização em equipamentos cujo acesso é comprometido. Além disso em equipamentos cuja variação de temperatura é notável em vários pontos do equipamento, uma câmara termográfica permite uma avaliação geral, rápida e fácil de interpretar.




Figura 2.5: Imagens captadas por uma câmara termográfica em componentes mecânicos e eléctricos.

2.2.3 Análise Elétrica

Os equipamentos eléctricos representam, em grande parte, a maioria do capital investido de uma organização. Desde quadros eléctricos até simples atuadores, o funcionamento eficiente do sistema eléctrico é crucial para manter a capacidade operacional.

A monitorização de parâmetros chave tais como desequilíbrios de fase, falhas de isolamentos, fatores de potência, voltagem, corrente são alguns dos elementos a ter em conta neste tipo de análise.

Trata-se de uma técnica que é de extrema utilidade e que permite identificar problemas eléctricos e mecânicos, em situações com máquinas de difícil acesso, alimentadas com inversores de frequência ou em situações para as quais a análise de vibrações não é aplicável.

O motores eléctricos são amplamente utilizados em inúmeros setores industriais, visto que são equipamentos altamente confiáveis devido à sua construção e testes em fábrica. No

¹Adaptado do site, consultado a 29-06-2016 em [http : //www.multierri.com.br/analise – termografica](http://www.multierri.com.br/analise-termografica).

entanto, estão sujeitos a várias situações que afetam o seu bom funcionamento, o que consequentemente, se traduzirá na diminuição do seu desempenho e vida útil.

Seguindo o guia de especificações de motores elétricos da WEG[22] pode-se observar na figura 2.6 que existe uma variedade enorme de motores elétricos que obriga a uma análise particularizada. Existem dois grandes grupos: o de corrente alternada (AC) e os de corrente contínua (DC). Como subcategorias nos AC, surgem os trifásicos e os monofásicos, enquanto que nos DC, a variedade é maior, com os passo-a-passo, os sem escovas, os convencionais e os servomotores.

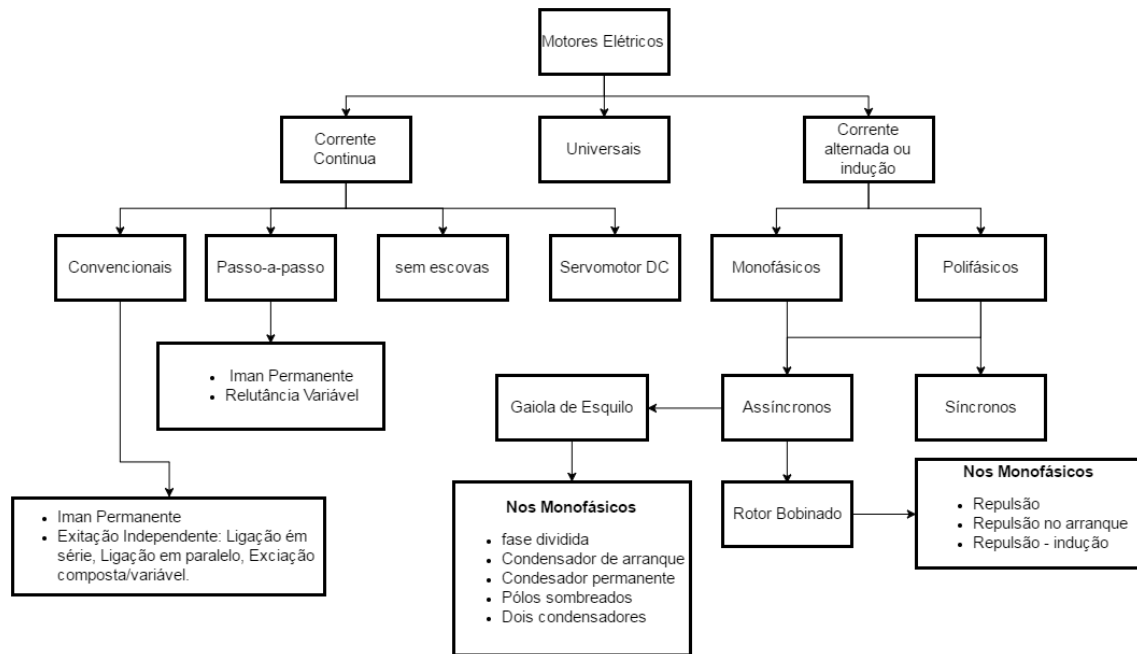


Figura 2.6: Esquema com todos os tipos de motores elétricos.

Com várias fábricas a trabalhar continuamente (24h/24h), sem paragens de produção que, eventualmente, podem originar torna-se fundamental evitar falhas inesperadas, que normalmente origina atrasos produtivos, traduzindo-se em elevadas perdas financeiras.

O programa de manutenção preditiva deve ser aplicado com as medições técnicas apropriadas para identificar e localizar as causas das alterações na performance do motor. Baseado nos resultados, o ideal é localizar o momento mais propício, para aplicar ações corretivas. Com a finalidade de monitorizar o desempenho dos motores elétricos e aplicar manutenção preditiva, um relatório técnico publicado pelo *Electric Power Research Institute* [23] apresenta várias formas de interpretar os resultados, das quais se destacam:

- Medição da voltagem - Os motores standard permitem operações dentro de uma voltagem num intervalo de mais ou menos 10% da voltagem recomendada para o motor. A operação de voltagem demasiado baixa aumenta a temperatura do estator e das asas do

rotor, enquanto que a elevada reduz a temperatura do motor. O desequilíbrio aceite entre a voltagem é de cerca de 1 % para motores de baixa voltagem, não podendo exceder os 5 % para motores de grande dimensão.

- Medição da corrente - Os valores de corrente nas três fases devem ser os mesmos ou menores que os apresentados na placa de características do motor, tendo aproximadamente o mesmo valor em cada uma. Quando detetados picos de corrente, a uma determinada frequência, pode ser um indicador de barras do rotor desgastadas. Partindo do facto de que a temperatura do enrolamento é proporcional ao quadrado da corrente em funcionamento, o aumento de 5% corresponde ao aumento de 25% a temperatura dos enrolamentos, causando um desgaste no isolamento eléctrico.
- Fator de potência - O fator de potência e o dimensionamento do motor estão estritamente correlacionados, se o primeiro estiver em sobrecarga, o segundo reduzirá. Este parâmetro definido, em corrente alternada, pela razão entre a potência ativa com a aparente. O valor ideal deste fator é apresentado na chapa de características do equipamento.
- Teste ao isolamento - Esta é a condição do isolamento entre o condutor e a terra. Valores baixos são um indicador da presença de sujidade, humidade no motor ou então falha no isolamento. Tais condições podem levar a falhas de isolação, resultando em perda de produção ou mesmo ignições acidentais.

O método de diagnóstico de falhas em motores apenas através de variáveis eléctricas é considerado uma ferramenta poderosa para a manutenção preditiva, tal como a análise de vibração.

Um outro fator deriva da análise dos efeitos dos harmónicos nos equipamentos eléctricos (qualidade da energia) com muita influência na avaliação e estimativa do tempo de vida, este fator pode produzir maiores esforços nos componentes, nos isolantes e nas alterações no desempenho do equipamento e pode pressupor uma falha do equipamento.

O grau com que harmónicos podem ser suportadas pelo sistema está directamente ligado ao fator de potência. Existem equipamentos menos sensíveis como é caso de equipamentos de aquecimento (carga resistiva), para os quais a forma de onda não é relevante, até aos mais sensíveis que é o caso dos equipamentos de comunicação e processamento de dados.

- Motores e geradores

Nas máquinas rotativas (indução e síncrona), o maior efeito dos harmónicos reflete-se no aumento da temperatura, devido ao aumento das perdas no ferro e cobre, e num aumento do ruído audível, quando comparado com a alimentação sinusoidal.

- Transformadores

De forma idêntica aos motores e geradores, também nestes componentes ocorrem perdas, isto deve-se a uma redução da área condutora à medida que a frequência elétrica aumenta.

2.2.4 Equipamentos utilizados para análise

Existem diversas marcas que disponibilizam equipamentos para os tipos de análise referidos anteriormente; consultados alguns fornecedores a operar a nível nacional como a Fluke¹ ou a Ffonseca², foram explorados alguns deles.

Para a análise térmica, o equipamento que mais se destaca são as câmaras termográfica que, como podemos ver na figura 2.7a, podem ser portáteis e registam uma imagem com a identificação da temperatura nos pontos observados pela mesma, permitindo detetar potenciais problemas. Uma outra alternativa mais económica é o uso de sensores resistivos ou termopares.

Para análise elétrica, os equipamentos a salientar são os analisadores de energia que permitem monitorizar uma série de parâmetros, tais como a medição e o registo de distúrbios elétricos - harmónicos, fator de potência, desequilíbrio e flutuação de tensão, variações de tensão de curta duração, entre outros. A figura 2.7b apresenta um exemplo desse equipamento.

Relativamente à análise de vibrações, os equipamentos apresentados nas figuras 2.7c e 2.8c registam contínua ou periodicamente as vibrações registadas, detetando variações irregulares que podem resultar em falhas mecânicas, como por exemplo, rolamentos ou engrenagens com desgaste.

Estes equipamentos podem, por um lado, ser portáteis (figura 2.7) e permitir monitorizações periódicas mais gerais, por outro lado, existem os fixos (figura 2.8) para colocação em equipamentos que necessitam de uma monitorização contínua e num ponto em concreto.



Figura 2.7: Exemplo de equipamentos portáteis utilizados para cada tipo de análise.

¹<http://www.fluke.com>

²<http://www.ffonseca.com/>



Figura 2.8: Exemplo de equipamentos fixos utilizados para cada tipo de análise.

2.3 Soluções Existentes de Apoio à Manutenção

2.3.1 Simulação

Graças ao desenvolvimento de *software*, as simulações tornaram-se uma ferramenta cada vez mais relevante e realista que podem ser aplicadas em diversas áreas, como por exemplo, necessidades dos clientes, produção, serviços, logística, estimativas de tempos de intervenção, entre outros. As simulações têm aumentado a sua popularidade, como ferramenta de auxílio à decisão, por gestores de todas as áreas.

Nos trabalhos divulgados na literatura técnica constam os diversos benefícios obtidos com o uso da simulação computacional [24]. São de destacar as seguintes vantagens: através dos modelos de simulação é possível estimar o que precisa ser melhorado e o momento mais oportuno, o que facilita, portanto, a tomada de decisões; inovações significativas e otimizações podem ser incrementadas através do uso da simulação computacional, uma vez que a animação do processo facilita o seu entendimento por parte dos gestores; a simulação permite avaliar a tomada de decisões, se esta é viável ou não, reduz gastos, tempo e evita interrupções inerentes à tradicional técnica de tentativa e erro [25].

Por outro lado, também existem complicações associadas, nomeadamente encontrar o *software* que melhor se adequa a cada cenário, procurando melhores parâmetros - desempenho, custo, tempo de aprendizagem, facilidade da implementação e a sua extensibilidade [24].

Verifica-se em muitos estudos, como por exemplo, em Bansal Evans e Jones [26], a necessidade da utilização de simulações, visto que a implementação destes modelos necessita de um extenso registo de valores dos equipamentos. Os autores referem considerar igualmente válido a utilização destes dados comparativamente aos reais.

No mercado existe uma panóplia *software* disponível que simula linhas produtivas, dos quais se destaca o *software* *Arena*, *FlexSim*. A simulação pode ser uma ferramenta interessante já que possibilita a redução de custos de implementação e o estudo de várias soluções

técnicas.

No âmbito desta dissertação, o *software Arena* foi utilizado e testado para pequenas simulações, tendo-se concluído que se trata de um *software* de rápida criação de simulações, contudo, denota-se algumas complicações na análise dos resultados, á medida que as simulações se complexificam (ver na figura 2.9 a sua interface).

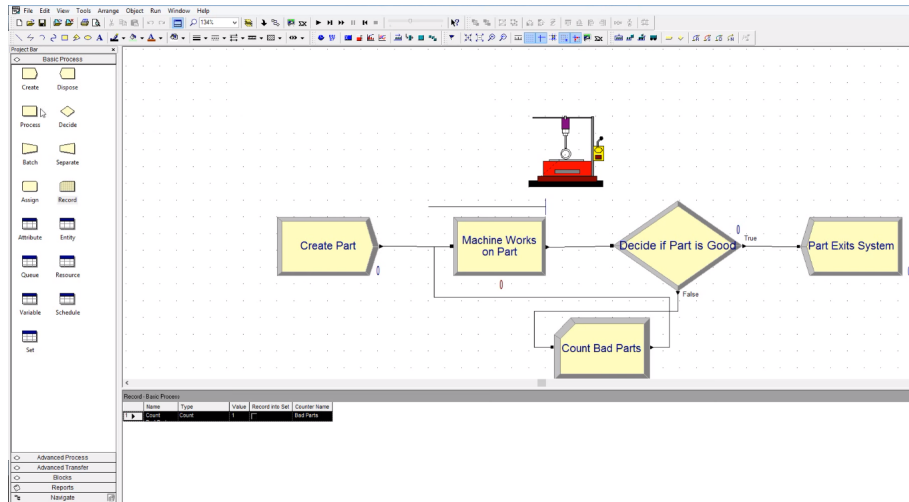


Figura 2.9: Interface *software Arena*.

2.3.2 Software SCADA

A expressão SCADA é a abreviatura para *Supervisory Control and Data Acquisition*, que se poderá traduzir para "Supervisionamento, Controlo e Aquisição de Dados". Esta sigla pode ser considerada uma boa síntese das principais capacidades de um programa deste tipo.

Na década de 60, foram criados pela *Westinghouse* e *GE* computadores capazes de executar funções em tempo real (*PRODAC* e *GETAC*) [27], que responderam com eficácia à complexidade requerida para a construção de uma estação mestre, capazes de fornecer todas as informações para um sistema SCADA, reconhecendo-se, deste modo, a vantagem na utilização de computadores com níveis superior de processamento.

A indústria começou por demonstrar um grande interesse por este tipo de aplicações, o que contribuiu para o seu rápido e crescente desenvolvimento, dado que permite aumentar a produção, além de reduzir custos como o consumo de energia e mão-de-obra, melhorando até as condições de segurança e qualidade no trabalho.

Existe um grande leque de *software* deste tipo disponíveis no mercado, sendo de destacar o *Movicon* e o *Lookout*; o primeiro foi desenvolvido pela *Progea* e o segundo pela *National Instruments*.

Ao consultar os manuais do utilizador destes *software* [28, 29], observa-se que denotam poucas diferenças em termos de funcionalidades.

Em primeiro lugar, surge o *Movicon* que é uma plataforma de SCADA/HMI (Inter-

face homem máquina) que "garante flexibilidade de desenvolvimento, versatilidade e independência"¹, mas também fluxo de informação em tempo real, entre setores, mesmo em empresas de grandes dimensões. A figura 2.10a apresenta um exemplo de um HMI criado na aplicação, contendo símbolos dinâmicos, estáticos e animações. Trata-se de uma tecnologia baseada em *eXtensive Markup Language* (XML), uma metalinguagem definida pelo padrão internacional do consórcio W3C. Esta linguagem caracteriza-se pela capacidade de facilitar a partilha de informações num determinado sistema.

O *Movicon* também possibilita a escrita e desenvolvimento de código em *Visual Basic* para Aplicações (VBA), comunicação com base de dados, alarmes, estatística e produção e proteção de dados.

O *software Lookout* é capaz de executar todas estas operações relevantes apresentadas anteriormente, não existindo diferenças significativas. A figura 2.10b apresenta um exemplo de HMI criado no *software*.

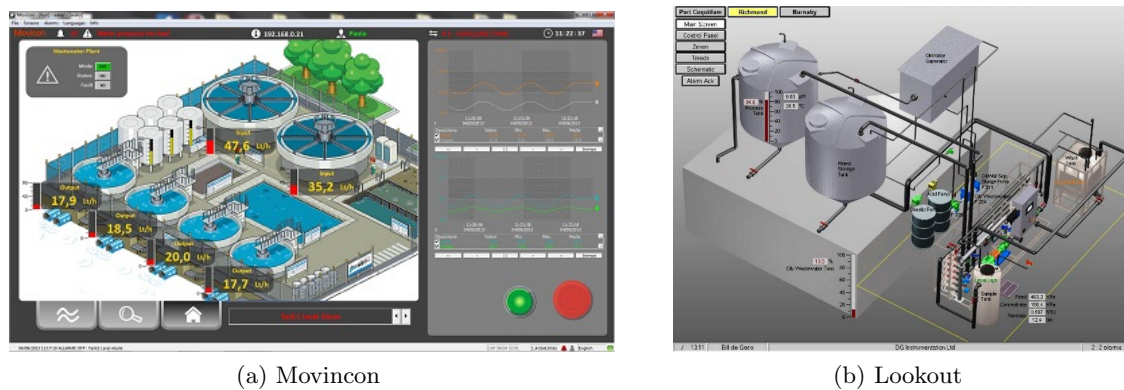


Figura 2.10: Interface exemplo de uma plataforma SCADA utilizando o *Movicon* 11 e o *Lookout*.

2.3.3 CMMS

Os sistemas computadorizados de gestão para a manutenção (CMMS) têm sido também cada vez mais frequentes na indústria, surgindo na década de 70 [30]. Atualmente torna-se cada vez mais importante a utilização deste tipo de *software*, quando existe um número significativo de equipamentos ou quando o recurso à manutenção é frequente.

A forte concorrência entre *software* disponíveis fez sobressair os aspetos menos positivos da implementação do CMMS e motivou a insatisfação das empresas, no entanto foram já desenvolvidas soluções com o intuito de facilitar a decisão [31].

Para além de ser um tarefa crucial e de extrema importância, seleccionar e avaliar que *software* CMMS escolher é um tarefa complicada, uma vez que a escolha errada pode tornar

¹Retirado do sitio <http://www.progea.com/>.

tudo o processo ineficaz.

Quando não existia o CMMS, a manutenção preventiva era gerida com muito pouco suporte de softwares, enquanto que atualmente é um apoio para diversas funções tais como [32]:

- controlar todos os ativos que necessitam de manutenção
- controlar o número de todos os ativos disponíveis, seus respectivos preços, etc
- agendar intervenções planeadas para a manutenção preditiva
- controlar a emissão de planos de manutenção, ordens de serviço
- fornecer orçamentação, manutenção e análises de custo
- inventário de manutenção
- fornecimento de ferramentas de análise para controlar e melhorar a performance da manutenção

A figura 2.11 apresenta a interface do *software* da *Maintenance Assistant*, empresa canadiana em Toronto que procura simplificar o mundo da manutenção. A aplicação funciona em plataforma *web browser* o que permite um acompanhamento das ordens de serviço e o agendamento de tarefas. Muitas da vezes as equipas de manutenção necessitam de profissionais exteriores à equipa, contudo, este produto também está preparado para esse tipo de situações, já que guarda os históricos de intervenções nos equipamentos, permite a gestão do inventário e oferece também a possibilidade de agendar intervenções seguindo uma manutenção preventiva¹.

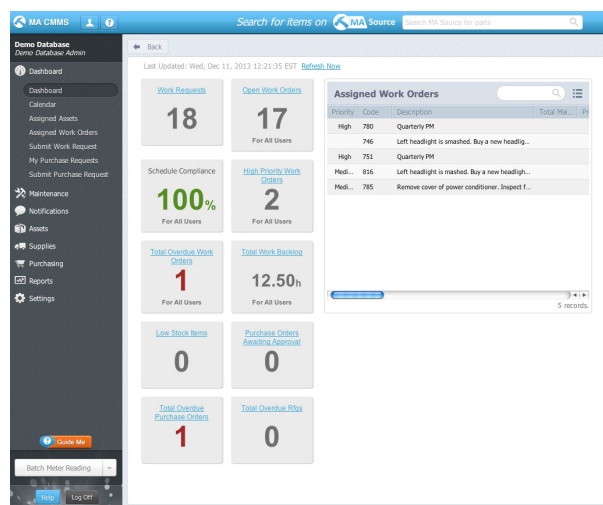


Figura 2.11: Exemplo de uma interface de *software* CMMS (MA CMMS software).

¹Retirado do site, consultado a 25-06-2016 em <https://www.maintenanceassistant.com/>.

2.3.4 Software SCADA e CMMS

Como foi dito anteriormente, o *software SCADA* de supervisão, controlo e aquisição de dados faz a recolha de informação adquirida através de múltiplos sensores, distribuídos por vários equipamentos ao longo das linhas de produção para um computador central.

Tendo um PLC ou até mesmo um microcontrolador a comunicar com o equipamento em análise, o sistema SCADA atua com um HMI (Human machine interface), fornecendo aos operadores um maior controlo e segurança.

Existem soluções no mercado que conciliam este *software* com o CMMS(*Computerized Maintenance Management System*) desenvolvidas por grandes companhias, como por exemplo a *General Motors Automation*.

A figura 2.12 representa a arquitetura de uma solução deste tipo³, trata-se de um ótimo recurso para apoio à equipa de manutenção com um registo de todas as intervenções a realizar, marcações de tarefas de manutenção a agendar, acompanhamento e criação de um histórico de todas as alterações efetuadas durante as reparações.

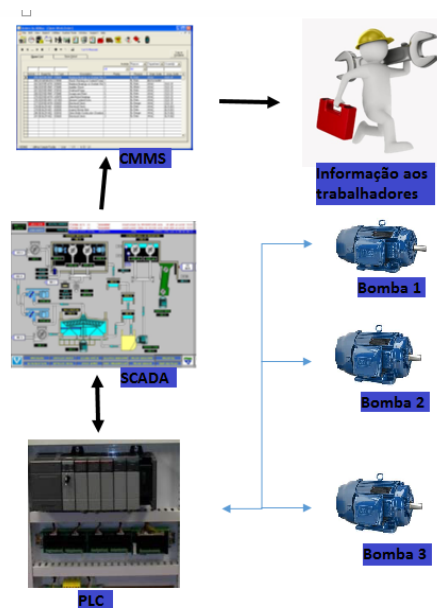


Figura 2.12: Esquema de Funcionamento SCADA e CMMS.

Com a aplicação destes dois *software* em simultâneo consegue-se adaptar mais finamente operações de manutenção programadas, evitando intervenções extemporâneas. A manutenção deve, como tal, ser proporcional á utilização da máquina, antecipando-se uma intervenção, em caso de sobrecarga ou protelando-a, em utilizações menos intensivas. Concretamente, supondo-se que um equipamento tenha agendada uma manutenção semanal, a carga de trabalho excessiva ou reduzida durante esse intervalo, pode inviabilizar a intervenção programada.

³adaptado do site e consultado a 24-07-2016 [http : //www.mi – wea.org/docs/CMMSsSCADA.pdf](http://www.mi-wea.org/docs/CMMSsSCADA.pdf)

Assim o *software SCADA* criará alarmes para que seja dada a ordem de reparação na hora certa, para não agravar problemas que conduzam à paragem da máquina.

Em suma, esta fusão retira o melhor de cada aplicação, já que consegue adquirir e armazenar os dados em tempo real e ao mesmo tempo gerir, otimizando o processo de manutenção, tanto preventiva como corretiva.

2.4 Execução de um Programa de Manutenção

Quando se sujeita um equipamento a uma manutenção preditiva (conforme ciclo representado na figura 2.13), devem ser feitas análises periódicas a um parâmetro ou mais, de acordo com cada tipo de máquina. Caso estes parâmetros ultrapassem os valores ideais de funcionamento, estipulados pelo fabricante, deve-se intervir para corrigir a causa dessa irregularidade.

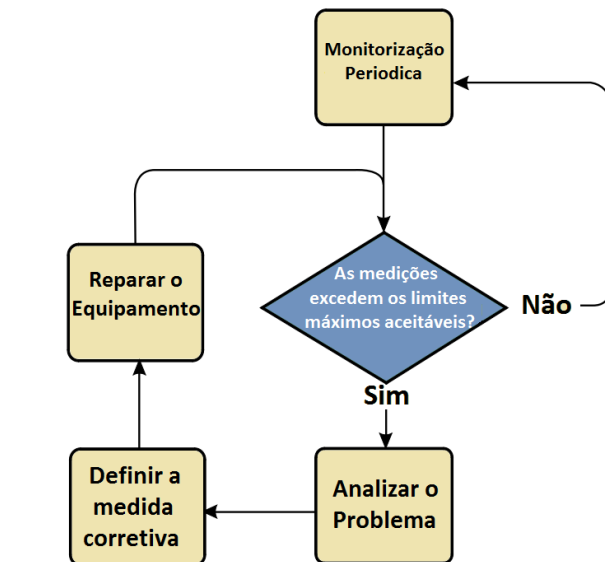


Figura 2.13: Esquema com o ciclo da Manutenção preditiva [17].

Como referido em capítulos anteriores a análise pode ser feita de várias formas, por exemplo, a vibração pode ser aplicada numa máquina rotativa. Um analista experiente pode diagnosticar problemas comuns, tais como desalinhamento e desequilíbrio, bem como problemas menos valorizados como a ressonância.

Uma vez o problema determinado, uma reparação mas apropriada pode ser aplicada; quando este estiver corrigido, o equipamento volta ao ciclo de monitorização periódica.

Posto isto, pode-se verificar que é importante fornecer um plano ao departamento de manutenção capaz de acompanhar e ajudar mais assertivamente a execução do trabalho de manutenção.

Existem quatro grandes ações que interferem no programa de manutenção: planeamento, programação, execução e monitorização [33].

Atualmente, não existe nenhuma norma que oriente o responsável de manutenção na criar um plano, existem sim várias propostas. Um ponto de partida possível para as necessidades que um plano deste tipo comporta pode ser a resposta aos seguintes tópicos[33] :

- Regras definidas pelo fornecedor
- Regras relativas à operação do ativo
- Questões legais
- Análise de risco, custos e tempos para a decisão do tipo de manutenção

Um plano de manutenção é um documento que deve prever todos os trabalhos preventivos de um equipamento, ao longo do seu ciclo de vida, este não deve ser um documento estático. As ações deste plano têm de apresentar uma certa periodicidade que pode ser fixada no calendário ou atender ao número de horas de funcionamento, neste último caso, a data de manutenção é marcada com base nos registros.

Com o objetivo de obter informação pormenorizada, Almeida[33] considera útil que, perante ativos de gestão, sejam seguidas boas práticas tais como:

- Considerar o manual do fabricante dos equipamentos: condições de utilização, histórico do equipamento e manual de utilização.
- Identificar as medidas de segurança por tipo de intervenção e equipamento
- Definir clara e objetivamente o tipo de intervenção, frequência e duração
- Descrever as tarefas a realizar e sequência de operações
- Selecionar responsáveis pela execução e pelo acompanhamento dos trabalhos
- Testar o equipamento de modo a verificar a sua funcionalidade (deve constar sempre no final de qualquer plano de manutenção)

Barbosa [34] propõe um plano de manutenção, resultante de um estudo que visa a otimização de um plano por meio da junção deste com o programa 5S.

O programa "5s" surgiu no Japão no início dos anos 50 por Kaoru Ishikawa, sendo amplamente utilizado à escala mundial. O "5s" é um programa que visa otimizar o fluxo de informações que gera organização, segurança, melhoria de layout, materiais, equipamentos e pessoas. A sua designação surge devido às etapas que o compõem iniciarem-se em japonês pela letra "S", que traduzidas são separação, ordenação, limpeza, padronização e disciplina.

A figura 2.14 representa um modelo proposto resultante desse estudo, quebrando o paradigma de que a manutenção é um setor dentro da empresa com grande desorganização,

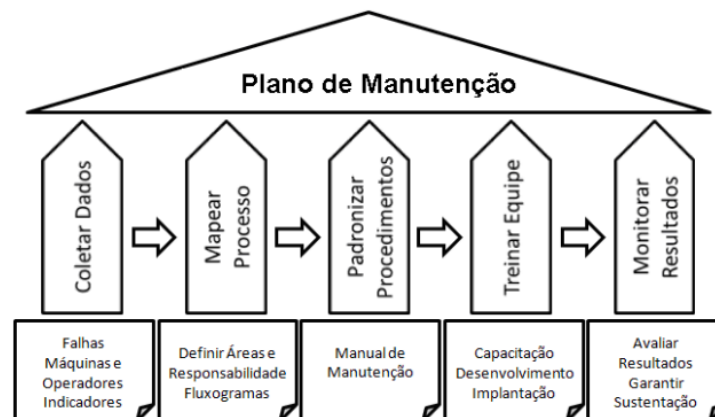


Figura 2.14: Exemplo de um modelo esquemático da elaboração e implantação do plano de manutenção.

falta de limpeza e falta de padronização. Divide-se em 5 etapas: coletar dados, mapear os processos, treinar a equipa de trabalho e por fim monitorizar os resultados.

Deste modo, a criação de um plano de manutenção é um ato que promove a organização e otimização de todo o departamento, tornando as intervenções mais assertivas e com medidas corretivas mais eficazes.

Capítulo 3

Metodologias Preditivas

A previsão envolve um cenário ou conjunto de valores numéricos que resulta no conhecimento do futuro através de indícios passados. É absolutamente essencial para o planejamento a curto e longo prazo. Esta ação permitirá privilegiar algumas decisões em detrimento de outras, possibilitando adaptar melhor o planejamento das atividades com o intuito de atingir os objetivos pretendidos. Embora seja impossível prever o futuro de forma completamente infalível, as técnicas de previsão procuram minimizar ao máximo os erros de previsão.

Este capítulo é de extrema relevância uma vez que nele serão estudados os métodos para prever as falhas inesperadas que resultam em danos colaterais no resto do equipamento e paragens de produção não programadas. No contexto dos sistemas mecânicos, a previsão da falha é considerada um evento de interesse e noutras áreas, como as ciências médicas, a previsão materializa-se no diagnóstico precoce de doenças potencialmente fatais para o ser vivo. Esta análise é usada com frequência na indústria para estimativas do tempo de vida, duração dos trabalhos, tempos de sobrevivência, em ensaios clínicos, ou até mesmo em áreas como a psicologia ou a sociologia [35].

Atualmente, verifica-se a existência de uma vasta panóplia de métodos para realizar previsões, desde métodos heurísticos a métodos com inteligência artificial. Como tal, é necessário identificar os diferentes tipos de previsões para que seja possível escolher o melhor modelo a aplicar no caso em estudo. Em seguida, serão abordados detalhadamente os principais e mais conhecidos métodos de previsão: modelos de Séries Temporais e métodos com inteligência artificial.

3.1 Séries Temporais

A maioria dos modelos de previsão estatística são baseados na utilização dos dados históricos a partir de uma série de tempo ou série temporal[36]. Uma série de tempo são todos os valores observados de uma unidade de interesse (uma variável aleatória) em relação

ao tempo.

Sendo uma série temporal uma descrição do passado, partindo de um procedimento lógico, pode-se chegar a um modelo matemático que é representativo do processo e que pode ser utilizado para gerar previsões.

Existem vários modelos de séries temporais [37] dividindo-se em duas classes: paramétricos, nos quais a análise é feita apenas pelos seus valores passados, e não paramétricos, quando a análise é feita no domínio dos seus valores passados, mas também por valores passados de outras variáveis. Além disto, as séries temporais têm características típicas como a tendência, ou seja a avaliação a longo prazo será de um comportamento constante, crescimento crescente ou decrescente, a sazonalidade, efeitos ligados a variações periódicas (semana, mensal, anual, etc.) e por fim os ciclos, variações que apesar de periódicas não são associadas automaticamente a nenhuma medida temporal. Os modelos propostos por Box e Jenkins [38], Auto regressivo (AR), médias Móveis (MA), Auto Regressivo com Médias Móveis (ARMA), Auto Regressivo Integrado com Médias Móveis (ARIMA) serão apresentados a seguir. Além disso modelos de amortecimento exponencial também serão abordados.

3.1.1 Características típicas de Séries Temporais

A maneira tradicional de analisar uma série temporal faz-se através da decomposição das suas componentes de tendência, ciclo e sazonalidade.

A tendência de uma série verifica-se segundo o seu comportamento a longo prazo, ou seja se esta apresenta um comportamento crescente, decrescente ou se permanece estável, e qual a velocidade a que estas mudanças ocorrem. Na prática, os casos mais frequentes são com tendência constante, linear ou quadrática. Na figura a seguir (3.1) demonstram-se os padrões que um série temporal pode apresentar.

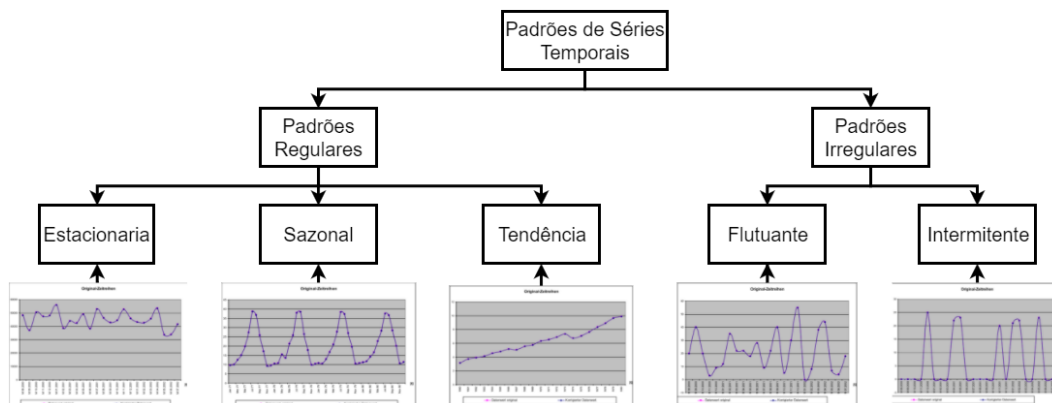


Figura 3.1: Tendência de uma série [39].

Diz-se que uma série é sazonal, quando a mesma tem flutuações periódicas que tipicamente

se identificam a partir de fatores externos que originam a série [40] ou então, dito por outras palavras, a sazonalidade consiste na oscilação em relação à tendência que ocorre mensalmente ou trimestralmente no decorrer do ano [41].

Sempre que se está perante uma série sazonal, deve-se incluir este facto no modelo da série. Para se detetar a sazonalidade de uma série, podem-se usar vários processos: pela observação gráfica da série e por um diagrama da função de autocorrelação.

Os ciclos são parte das observações da série que se repetem em períodos superiores a um ano. Um exemplo disso mesmo é os ciclos registados relacionados com a atividade económica ou ciclos meteorológicos.

3.1.2 Modelos autorregressivos(RA)

Segundo Vladimiro Miranda[40] num processo autorregressivo, o valor presente da série temporal X_t , representa linearmente os valores registados ao longo do tempo e da perturbação aleatória a ocorrer no instante t . A ordem deste processo depende do valor mais antigo sobre o qual a regressão tem lugar. Num processo autorregressivo de ordem p , o modelo pode escrever-se como:

$$X_t = \delta + \Theta_1 X_{t-1} + \Theta_2 X_{t-2} + \dots + \Theta_p X_{t-p} + a_t \quad (3.1)$$

em que os vários Θ_1 são constante reais e a série dos a_t apresenta distribuição normal de valores independentes.

3.1.3 Modelos de Média Móvel (MA)

Segundo o autor, em [41], os modelos de médias móveis são adequados para avaliar a tendência de uma série temporal e são muito sensíveis às alterações recentes do seu comportamento. De forma geral, utiliza a informação relativa aos termos da série numa vizinhança e, a partir da média, estima o seu nível corrente.

A definição em [39] para as médias móveis aponta para que a previsão seja apenas a média das últimas N observações, pertencendo à classe das séries temporais paramétricas. Um dos problemas neste método é escolher o tamanho da janela a ser utilizado, ou seja o valor de N . Quanto maior o N mais "suave" será a previsão, por outro lado, sendo pequeno a previsão tende a oscilar muito. Uma premissa fundamental para utilizar este método é que cada observação tem de ter o mesmo peso (que é $1/N$). Mas, na prática, é razoável supor que as observações mais recentes sejam as mais relevantes para a previsão dos próximos valores da série, e portanto deveriam receber um peso maior que as observações mais antigas. Esta ideia de pesar ou ponderar as observações de acordo com as suas "idades" leva aos diversos métodos

de amortecimento exponencial. O modelo pode escrever-se como [40]:

$$X_t = m + a_t - \gamma_1 a_{t-1} + \gamma_2 a_{t-2} + \dots + \gamma_p a_{t-p} \quad (3.2)$$

em que os vários γ_j são constantes reais e a_{t+n} os valores presentes e passados da série.

3.1.4 Modelos autorregressivos e de média móvel (ARMA)

Box e Jenkins popularizaram uma técnica que combina as características dos modelos autorregressivos AR e de média móvel MA [40]. Apesar de estes modelos serem anteriormente conhecidos, foram Box e Jenkins que contribuíram para o desenvolvimento de novas abordagens que tornaram o processo eficaz e sistemático na identificação de modelos que pudessem incorporar em simultâneo ambas as características. O processo do tipo ARMA combina os dois efeitos anteriores e para um processo de ordem p,q representa-se por:

$$X_t = \delta + \Theta_1 X_{t-1} + \Theta_2 X_{t-2} + \dots + \Theta_p X_{t-p} + a_t - \gamma_1 a_{t-1} + \gamma_2 a_{t-2} + \dots + \gamma_p a_{t-p} \quad (3.3)$$

O modelo de Box e Jenkins assume que a série é estacionária.

3.1.5 Modelos autorregressivos integrados de média móvel (ARIMA)

Como visto anteriormente, as ARIMA vêm contornar uma limitação do modelo ARMA, uma vez que este torna possível a aplicação deste método numa série não estacionária. Sendo uma série não estacionária terá de se recorrer à sua estacionarização. Com este processo proposto por Box e Jenkins, consegue-se obter operações de diferenciação, mesmo que aplicado sucessivas vezes.

À série estacionarizada aplica-se então o modelo ARMA. Assim, ARIMA corresponde então a um processo autorregressivo integrado com média móvel. O termo "integração" deve-se ao facto de a série original ser reconstruída a partir da série diferenciada, por uma operação de integração ou soma recursiva.

3.1.6 Modelos de amortecimento exponencial

Estes modelos utilizam ponderadores exponencialmente decrescentes como a antiguidade das observações. São de vários tipos [41]: modelos de alisamento exponencial simples, modelos de alisamento exponencial duplo, método de Holt e método Holt-Winters, para séries sazonais e não sazonais. O funcionamento geral é semelhante aos modelos de médias móveis, mas neste os pesos das observações decrescem à medida que as observações estão mais longe no passado. Os pesos são determinados por uma ou mais constantes de amortecimento. A maior dificuldade na aplicação prende-se com a escolha da constante adequada, no entanto existem *software* que ajustam os modelos de amortecimento automaticamente ao valor das constantes

otimizadas.

Estes métodos, na prática, são dos mais utilizados no dia a dia das empresas, quando estas necessitam de realizar uma previsão [39], este facto deve-se à fácil implementação, compreensão e à capacidade de gerar resultados bastante satisfatórios.

3.1.6.1 Amortecimento exponencial

Nos modelos de amortecimento, identificam-se dois tipos, o simples e o duplo [41]. O modelo de amortecimento exponencial simples é um modelo adequado para séries com tendências localmente estacionárias e sem movimentos sazonais, por outro lado, o duplo, também conhecido como método de Brown, é apropriado para séries que apresentam tendência linear e consiste na aplicação do método de alisamento exponencial simples duas vezes, utilizando a mesma constante de alisamento [41].

Começando pelo modelo de amortecimento exponencial simples, para os valores futuros da série utilizam-se as estimativas mais atualizadas do nível da série, através da expressão:

$$M_t = \alpha Y_t + (1 - \alpha)M_{t-1}, \text{ com } 0 < \alpha < 1 \quad (3.4)$$

Em que M_t é a estimativa do nível da série no momento t e α a constante de amortecimento ou alisamento. Para conseguir obter previsões, deve-se escolher um valor inicial para M_t (geralmente, este valor é obtido pelas médias das observações iniciais da série) e um valor para a constante de alisamento.

Relativamente ao outro tipo de amortecimento exponencial, o duplo, utilizam-se as seguintes equações:

$$M_t = \alpha Y_t + (1 - \alpha)M_{t-1} \quad D_t = \alpha M_t + (1 - \alpha)D_{t-1} \quad (3.5)$$

Sendo M_t a série de amortecimento simples, D_t a série de amortecimento exponencial duplo e α a constante de amortecimento. Para obter, a partir deste método, as previsões utiliza-se a expressão:

$$\hat{Y}_{t+n} = \hat{a}(t) + \hat{b}(t)n \text{ em que : } \hat{a}(t) = 2M_t - D_t, \hat{b}(t) = (M_t - D_t)[\alpha/(1 - \alpha)] \quad (3.6)$$

Em que $\hat{a}(t)$ e $\hat{b}(t)$ são estimativas do nível de declive da série.

3.1.6.2 Método de Holt e Holt-Winters

Os métodos Holt e Holt-Winters são ambos adequados a séries com tendência linear, no entanto, o método Holt aplica-se sobretudo a séries sem sazonalidade, enquanto que o de Holt-Winters é indicado para séries com sazonalidade.

O método de Holt é muito semelhante ao exponencial duplo, mas este tem duas constantes

de amortecimento diferente, uma responsável pela rapidez com que varia o coeficiente linear e a outra pelo angular. Este método é implementado pelas seguintes equações [39]:

$$M_t = \alpha Z_t + (1 - \alpha)(M_{T-1} + \hat{a}_2(T-1))\hat{a}_2(T) = \beta(M_T - M_{T-1}) + (1 - \beta)\hat{a}_2(T-1)\hat{a}_1(T) = M_T \quad (3.7)$$

onde α e β são as constantes de amortecimento.

3.2 Métodos com Inteligência Artificial

Os algoritmos têm cada vez mais importância nos dias de hoje devido à ânsia do ser humano em perceber e controlar o mundo. Essa necessidade acaba por criar, gradualmente, grande conhecimento nestas áreas o que permite prever acontecimentos em múltiplas áreas, como por exemplo, o movimento dos planetas, o estudo de doenças, entre outros [42].

Pelos fatos anteriormente referidos e com o objetivo concreto de prever avarias nos equipamentos, é de extrema importância analisar formas que ajudem a prever, e os algoritmos são uma excelente ferramenta na que é de superior importância investigar.

Na literatura existem inúmeros estudos sobre a otimização de programas de manutenção, que combinados com algoritmos são excelentes ferramentas para a resolução de problemas. Mohanta [43] combinou algoritmos genéticos com o algoritmo SA (Simulated Annealing) na otimização de confiabilidade e segurança de uma central elétrica. O algoritmo PSO (Particle swarm optimization) foi utilizado por Pereira [44] para a otimização da manutenção preventiva não periódica de uma estação nuclear, com o intuito de otimizar o agendamento das intervenções. Por fim, Yuo-Tem Tsai [45] utiliza algoritmos genéticos para a otimização da manutenção preventiva para componentes mecânicos.

3.2.1 Árvores de decisão

As árvores de decisão são modelos frequentemente utilizados e de fácil implementação em inferência indutiva. Estes modelos são treinados de acordo com um conjunto de parâmetros de treino (variáveis classificadas previamente), originando modelos matemáticos que, virtualmente, decidirão a classificação de novas variáveis de entrada. Existem algoritmos como o ID3, ASSISTANT e C4.5, que constroem estas árvores [46]. Este método aplicado à manutenção permitirá tomar decisões com antecedência relativamente à falha.

Utilizando um exemplo adaptado, no âmbito de previsão de falha, o objetivo é decidir se um motor elétrico tem probabilidade de falha ou não. Para tal, há que ter em conta certos parâmetros como a temperatura registada, a corrente, o desempenho e o ruído. Cada um destas variáveis apresenta diversos valores. Por exemplo, para a temperatura pode estar "alta", "ideal" ou "baixa", considerando de forma idêntica para os restantes parâmetros de entrada. O resultado da simulação pode resultar em "Sim" (há probabilidade de ocorrer falha) ou

”Não” (não deverá ocorrer falhas) alertando assim para a existência ou não de avaria.

A título explicativo, para construir a Árvore de decisão de intervir são tidos em conta exemplos (dias) passados.

Tabela 3.1: Tabela meramente ilustrativa, valores não provados. Adaptado de [46].

Dia	Temperatura	Corrente	Ruído	Desempenho	Falhar
D1	Alta	Alta	Normal	Baixo	Sim
D2	Alta	Alta	Normal	Alto	Sim
D3	Normal	Alta	Normal	Baixo	Não
D4	Baixa	Alta	Anormal	Baixo	Sim
D5	Baixa	Baixa	Normal	Baixo	Sim
D6	Baixa	Baixa	Anormal	Alto	Não
D7	Normal	Baixa	Normal	Baixo	Não
D8	Alta	Alta	Normal	Baixo	Sim
D9	Alta	Baixa	Normal	Baixo	Sim
D10	Baixa	Baixa	Anormal	Alto	Não
D11	Alta	Baixa	Anormal	Alto	Sim
D12	Normal	Alta	Anormal	Alto	Não
D13	Normal	Baixa	Normal	Baixo	Não
D14	Baixa	Alta	Anormal	Alto	Não

Através destes exemplos é possível construir a seguinte árvore de decisão:

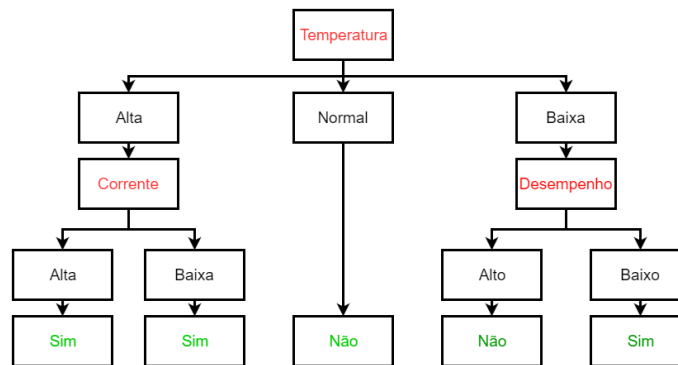


Figura 3.2: Tabela meramente ilustrativa, valores não provados. Adaptado de [46].

As relações entre, temperatura, desempenho e corrente são os nós internos que testam os atributos, cujas ramificações correspondem a um valor. Deles saem as ”folhas” da árvore que atribui uma classificação. Com esta árvore, a classificação de um novo parâmetro de entrada (por exemplo, temperatura alta), resulta em ”sim” (deverá ocorrer falhas), independentemente dos outros resultados que não alterariam a classificação.

Com as árvores de decisão é possível representar a conjunção e disjunção de atributos. As árvores apresentam a interseção de dois atributos e a reunião de outros dois.

3.2.1.1 Algoritmo ID3

O algoritmo ID3 (*inductive decision tree*) é um dos mais utilizados na construção de árvores de decisão. Tipicamente, este algoritmo começa com todos os exemplos de treino, escolhe o teste (atributo), divide e agrupa exemplos da mesma classe ou semelhantes, para

o atributo escolhido, cria um nó filho para cada valor possível do atributo, transporta os exemplos para cada filho, tendo em conta o valor do mesmo e, por fim, repete o procedimento para cada filho não "puro" ou por outras palavras, sempre que um atributo X tem o mesmo valor em todos os exemplos irá voltar a repetir o procedimento.

Para identificar qual o melhor atributo a escolher são introduzidos dois novos conceitos, a Entropia e o Ganho.

A entropia é uma medida de aleatoriedade de uma variável [47]. Para uma variável nominal x a sua entropia é calculada da seguinte maneira:

$$entropia(X) = - \sum (p_i \log_2 p_i) \quad (3.8)$$

com instâncias pertencentes à classe i , como probabilidade p_i . Portanto esta equação pode ter como resultados os representados na figura 3.3.




Figura 3.3: Gráfico com relação entropia/erro. Retirado de [47].

Relativamente ao ganho, este define a redução na entropia e é dado pela seguinte equação:

$$Ganho(X, A) = Entropia(X) - \sum_{v \in \text{valores}(A)} \frac{|S_v|}{|S|} Entropia(S_v) \quad (3.9)$$

Em que esta igualdade representa a redução esperada pela entropia de X , definida pelo atributo A .

Por fim, existem também critérios de paragem, ou seja o momento em que se deve parar a divisão dos exemplos. O primeiro critério é quando todos os exemplos pertencem à mesma classe, o segundo, quando todos os exemplos de classes diferentes têm os mesmos valores dos atributos e por fim, quando o número de exemplos é inferior a um limite definido.

3.2.2 Redes Neurais

Em Portugal, nos últimos anos tem-se assistido a um maior interesse das empresas por esta área da inteligência artificial, são exemplos a CGD na área de sistemas periciais para

avaliação dos empréstimos a empresas, o grupo Sonae, na área de *data mining*, para análise de bases de dados de vendas nos seus hipermercados e a Portugal Telecom para análise dos dados provenientes das suas filiais [48].

Este também é um método com muito potencial para a previsão de avarias de equipamentos. Existem muitos estudos de sucesso que utilizam esta técnica, como Basal na aplicação de um sistema de manutenção preditiva em tempo real para um sistema de máquinas produtivas [26, 49, 50], Carnero também utiliza este método para a seleção do diagnóstico, técnicas e instrumentação num programa de manutenção preditiva [51].

Posto isto, a figura 3.4 vemos os vários tipos de redes neuronais existentes.

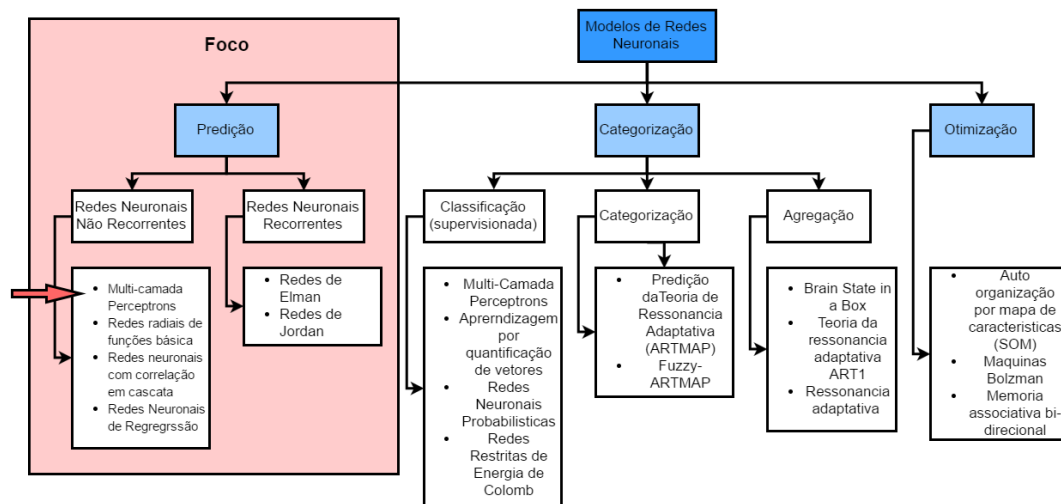


Figura 3.4: Categorização dos diferente tipos de Redes Neuronais.

Assim, verifica-se que se dividem em três áreas de aplicação, predição, categorização e otimização. O foco desta dissertação será na área da predição, mais concretamente *perceptrons* multi-camada.

No processo de modelação de uma rede neuronal, há uma série de decisões que têm de ser tomadas, como podemos ver na figura a seguir (3.5), desde a preparação dos dados, configuração da rede neuronal, escolha dos algoritmos, aplicação e por fim avaliação dos resultados. Todas estas etapas serão abordadas nos tópicos a seguir.

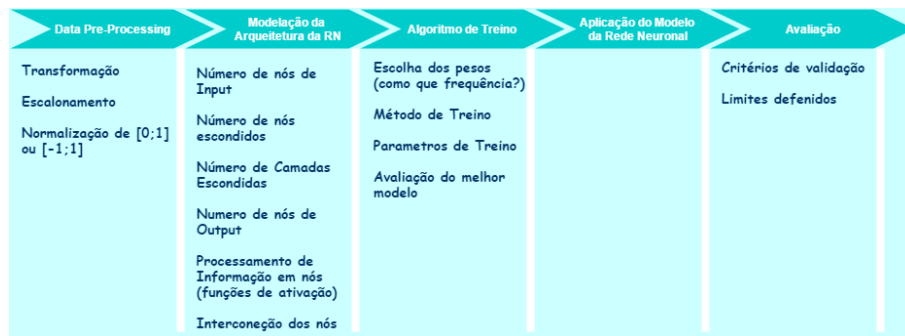


Figura 3.5: Processo de Modelação das Redes Neurais adaptado de [52].

3.2.2.1 Componentes e Arquitetura de uma Rede Neuronal

As redes neuronais artificiais (*artificial neural networks*) são modelos simplificados inspirados no funcionamento neuronal de organismos inteligentes, que adquirem conhecimento através da experiência, constituída por simples unidades de processamento (neurónios ou nós). Estas unidades são interconectadas através de pesos, que são valores numéricos, representando as sinapses. Elas são responsáveis por determinar uma saída que servirá de entrada para outra unidade [53].

Na figura 3.6 está representada a estrutura do neurónio artificial proposto por McCulloch e Pitts que é baseada no neurónio biológico, em que a maior limitação é a sua natureza binária. Se a soma ponderada dos sinais de entrada de um neurónio ultrapassar um determinado limite de disparo, então a saída toma valor 1, se não ultrapassar, toma o valor zero.

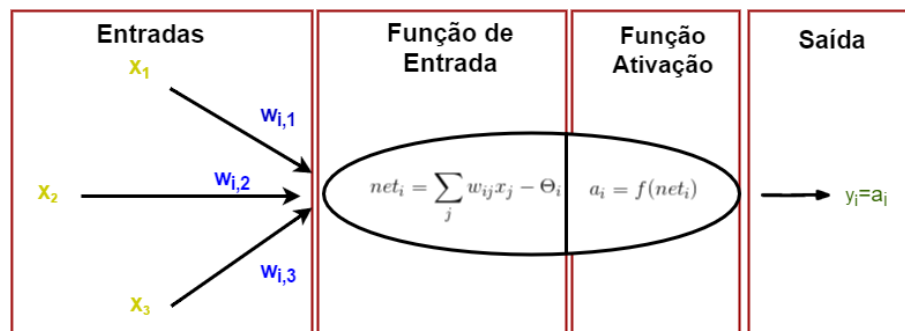


Figura 3.6: Modelo matemático do neurónio proposto por McCulloch e Pitts.

Como podemos observar em 3.6, aos sinais de entrada são associados pesos (w_{ji}) que criarão, por sua vez, uma função de entrada (net_i) á qual será associada uma função de ativação, resultando em parâmetros de saída. No valor limite de ativação dos neurónios, a função de ativação é bastante sensível no aspeto biológico e representa a altura em que o neurónio envia sinapses. Esta função de ativação mais usada é a função Sigmóide, represen-

tada pela equação a seguir [54]:

$$f(net_i) = \frac{1}{(1 + e^{-x})} \quad (3.10)$$

em que o alcance destes valores varia de $[0;1]$ neste caso; existe também a alternativa de usar a tangente hiperbólica sendo que os valores variam de $[-1;1]$. Matematicamente, os valores limites de ativação para a função 3.10 são representados da seguinte maneira:

$$y_i = \begin{cases} 1 & \text{se } \sum_j w_{ji}x_j - \Theta_i \geq 0 \\ 0 & \text{se } \sum_j w_{ji}x_j - \Theta_i < 0 \end{cases} \quad (3.11)$$

em que w_{ji} representa os pesos e Θ designa-se por bias (inclinação).

Quanto á arquitetura, os neurónios estão organizados graficamente e ligados entre si com uma orientação, cuja estrutura define a arquitetura para redes neuronais artificiais, no entanto, as mais utilizadas são as redes totalmente conectadas, as redes de camada única e as redes multicamada.

3.2.2.2 O modelo *Perceptron* de Multi-Camadas

Na literatura existem muitos modelos de redes neuronais e uma quantidade razoável de publicações que os desenvolvem e classificam. Dos modelos existentes, o mais utilizado é o *perceptron* multicamadas (MLP) cuja aprendizagem é inspirada no algoritmo de retropropagação, mais utilizado em áreas como processamento da fala e na previsão de séries temporais [55].

Este modelo foi proposto por Frank Rosenblatt em 1957, apresentando resultados de previsão muito satisfatórios. A arquitetura apresentada em 3.7, é composta por uma camada de entrada que é constituída pelas variáveis de entrada passando por processos de ativação em camadas intermediárias ou escondidas, sucessivamente até à camada de saída de onde resultarão as saídas, no caso em concreto as previsões.

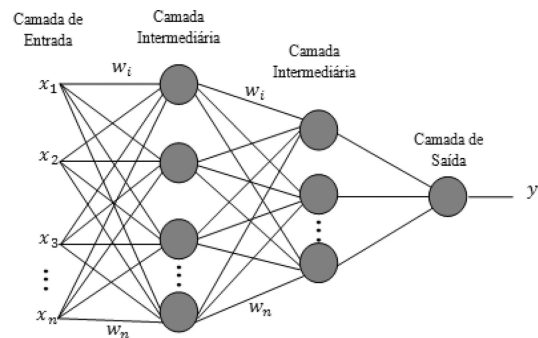


Figura 3.7: Rede Neuronal Multicamada (MLP).

Os neurónios agrupam-se por camadas e as suas conexões são unidirecionais, os pesos atribuídos aos neurónios intermédios resultam do treino da rede neuronal.

3.2.2.3 Processo de aprendizagem e algoritmos de treino

Um dos aspetos mais importantes das redes neuronais é a capacidade de aprender com base no seu ambiente e com isso melhorar o seu desempenho. Isto é feito com séries de valores de treino, para que a rede ajuste os pesos, chegando assim aos parâmetros ideais.

No processo de aprendizagem identificam-se três tipos de padrões: aprendizagem por reforço, supervisionada e não supervisionada [53].

Na aprendizagem supervisionada, de particular interesse neste estudo, há um conjunto de dados de entrada aos quais correspondem respetivamente valores de alvo. Neste sentido, a rede é treinada, adaptando os pesos das conexões de modo a que colocando novos valores de entrada se obtenha o valor de saída desejada. Os métodos a destacar neste tipo de aprendizagem são *perceptron* e *back-propagation* ou retropropagação.

A aprendizagem por reforço consiste basicamente num treino em que são dadas entradas com saídas incorretas, no entanto, sempre que a saída esteja correta é atribuído um prémio, todavia, se estiver errada, a rede recebe um castigo. As alterações dos pesos são apenas baseadas nos níveis de atividade entre unidades conectadas localmente [56]. Os principais modelos que se incluem neste método são Hebb e Hopfield.

A aprendizagem não supervisionada aplica-se quando não se dispõe, à priori, dos valores de saída ou não há qualquer indicação sobre possíveis classificadores. Esta aprendizagem ocorre como uma adaptação própria da rede, na deteção de irregularidades no espaço de entrada, sem *feedback* direto de um supervisor. Os principais modelos que se incluem neste método são as redes competitivas e as *Kohonen*.

Relativamente aos algoritmos de treino, a atualização dos valores de treino resultam a partir de regras de aprendizagem que se traduzem no esquema seguinte[57]:

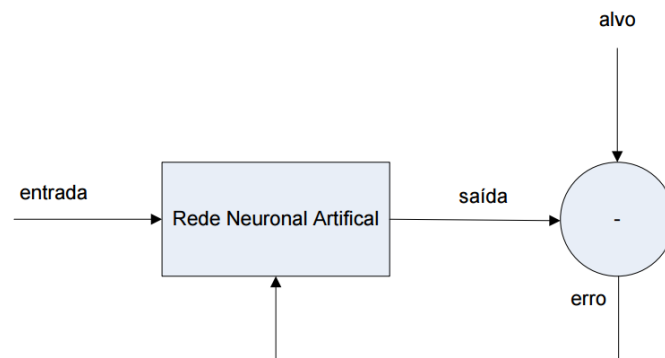


Figura 3.8: Representação do procedimento para ajuste dos parâmetros da RNA para o método de aprendizagem supervisionada.

A equação 3.12 resulta do procedimento apresentado em 3.8 que representa a forma como o ajuste dos valores de treino são processados em aprendizagem supervisionada. Desta equação resulta a saída real, a_j , o ajuste do peso do neurónio, j , com R entradas.

$$a_j = f(\Theta_j + \sum_{i=1}^R w_{ij}x_i) \quad (3.12)$$

Inicialmente o valor dos pesos w_{ji} e da variável θ_j são inicializados com valores aleatórios. Calculando assim a saída, a partir da função de ativação, f , à entrada real, as variáveis referidas anteriormente são atualizadas respetivamente pelas equações 3.13 e 3.14. Assim o peso varia consoante a diferença entre o valor da variável a que se quer chegar. t (target) e o valor obtido, y .

$$w_{ij} = w_{ij} + \alpha t - a_i p_i, \quad \alpha \in [0; 1] \quad (3.13)$$

$$\Theta_j = \Theta_j + \alpha t - a_i p_i, \quad \alpha \in [0; 1] \quad (3.14)$$

O ajuste do peso tem ainda associada uma taxa de aprendizagem α que controla a velocidade de convergência do procedimento. Quanto mais baixa for esta taxa, menores serão as variações dos pesos entre duas iterações de treino. No caso contrário, se a taxa de aprendizagem for elevada, as variações serão significativas o que pode tornar a rede instável ou oscilatória.

Este processo prosseguirá até atingir os critérios de paragem que são definidos previamente. A cada iteração está associado um valor de erro, assim que este atingir um valor admissível, dá-se o treino por concluído.

Este algoritmo tem as suas limitações, apenas permite treinar redes neuronais de uma camada, possibilitando a aplicação em problemas simples de natureza linear [57]. Nos casos mais complexos, normalmente é necessário uma arquitetura multicamada (MLP), bem como um algoritmo adequado.

Em suma, as redes neuronais não são programadas para resolver problemas, elas são treinadas, sendo que após o treino, estão prontas para serem utilizadas.

3.2.2.4 Algoritmos de *Back-Propagation*

As redes *perceptron* multicamada, como foi dito, são dos métodos mais utilizados e eficientes, com capacidade de resolução de problemas complexos, através de treinos supervisionados e com o algoritmos popularmente designados por *back-propagation* (BP).

Na figura 3.9 está apresentada uma rede neuronal com retropropagação em que os valores de entrada "fluem" no sentido das entradas para as saídas *feed-forward*, enquanto que o erro se propaga inversamente, daí a origem do nome deste algoritmo.

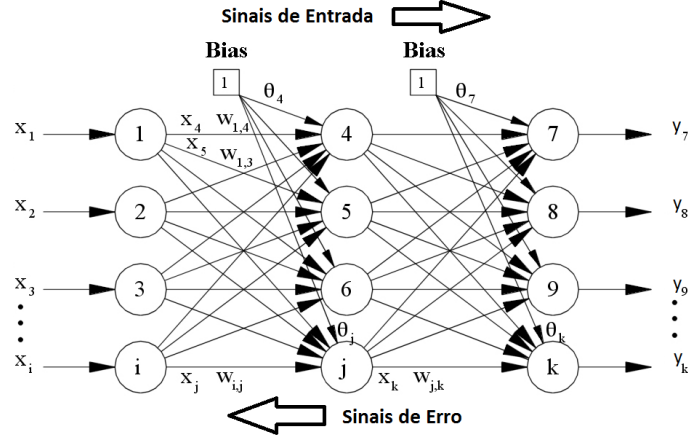


Figura 3.9: Rede Neuronal com *Back Propagation*. <http://www.cse.unsw.edu.au/cs9417ml/MLP2/BackProp>

Esta lógica começa por inicializar as conexões com pesos aleatórios, processando as entradas no sentido para a frente (*forward-propagation*), resultando na camada de saída. Em seguida, calcula o erro entre os resultados obtidos e os reais, começando assim o processo de retropropagação; o erro de cada peso, que inicialmente foi colocado aleatoriamente, agora será corrigido, embora não esteja ainda com valores ideais. Assim, processa novos valores de treino, ajustando de forma idêntica, de modo a terem o menor erro possível [52].

A variação do peso entre neurónios é dada pela equação 3.15 e o erro que será retropropagado nas camadas escondidas (δ_j) é dado pela equação 3.16, sendo que y_i é o sinal de entrada do neurónio j .

$$\Delta w_{ij} = \alpha y_i \delta_j \quad (3.15)$$

$$\delta_j = f'_j(\text{net}_j) \sum \delta_k w_{kj} \quad (3.16)$$

De forma idêntica à equação 3.16 observa-se a equação 3.17 que representa o erro a retropropagar-se nas unidades de saída.

$$\delta_j = f'_j(\text{net}_j) (t_i - y_j) \quad (3.17)$$

A regra utilizada neste processo de treino designa-se por gradiente descendente; consiste na repro-propagação do erro durante a aprendizagem que controla a variação da função do erro em relação ao vetor de pesos. Quando esta variação for suficientemente pequena, considera-se que a rede convergiu conforme o pretendido para a solução esperada [54].

3.2.2.5 Algoritmos baseados em *back-propagation*

Com o objetivo de eliminar a dificuldade que existe em determinar a taxa de aprendizagem ótima para cada iteração, surge uma constante positiva designada por *momentum* [57]. A equação 3.18 representa a forma como a atualização dos pesos com *momentum* é feita e completa a equação 3.15, adicionando um termo que provoca um efeito estabilizador durante a convergência. Numa iteração n , a atualização dos pesos é feita com a função do erro e também com o valor dos pesos em $n-1$, fator N . Esta variável irá funcionar como uma memória, acelerando as descidas do gradiente, evitando em alguns casos que o processo de aprendizagem termine num mínimo local da superfície de erro.

$$\Delta w_{ji}(n) = \eta \Delta w_{ji}(n-1) + \alpha \delta_j(n) y_i(n) \quad (3.18)$$

Com o intuito de melhorar a performance, foram aparecendo novos algoritmos de treino, que se baseiam no algoritmo de *back-propagation*, introduzindo novos conceitos, como técnicas de otimização e heurística.

O Método de *Newton*, *Levenberg-Marquardt*, *Resilient Back-propagation*, *Conjugate Gradient* e *One Step Secant* são alguns exemplos desses algoritmos.

- Método de *Newton*

Trata-se de um método de otimização que se baseia na computação da matriz *Hessiana*. Esta matriz *Hessiana* é composta pelas derivadas de segunda ordem dos erros em função dos pesos sinápticos. Trata-se de um método complexo e computacionalmente exigente. No entanto, este método tem a vantagem de convergir em poucas iterações, sendo eficaz em redes neurais de dimensões reduzidas.

- *Levenberg-Marquardt*

Este método processa-se de forma semelhante ao anterior e aproxima a matriz *Hessiana*, com recurso à matriz *Jacobiana*, cujas linhas são constituídas por exemplos particulares de um conjunto de treino. Assim, este método torna-se menos exigente computacionalmente e, além disso, o algoritmo converge em poucas iterações, embora necessitem de mais memória.

Este algoritmo mostra-se uma solução bastante eficiente, quando aplicada em redes neurais de elevada dimensão.

Capítulo 4

Solução Proposta e Implementação

4.1 Solução Proposta

Esta secção pretende descrever de formal geral a solução e implementação proposta desenvolvida ao longo desta dissertação.

4.1.1 Arquitetura do protótipo

Nesta dissertação, propõe-se uma solução que pretende interligar os 3 níveis de gestão e facilitar o acesso à informação de redes industriais a partir do chamado "chão de fábrica", nomeadamente os sensores, atuadores e HMI, passando pelos dispositivos de controlo e sistemas de supervisão, até á gestão da produção, conforme figura 4.1. Esta plataforma integra os respetivos níveis com o intuito de tornar a manutenção mais eficiente e com a capacidade de predição das falhas dos equipamentos antes destes chegarem a parar ou então evitar as consequências do mau funcionamento que aumentariam a probabilidade de ocorrência da avaria.

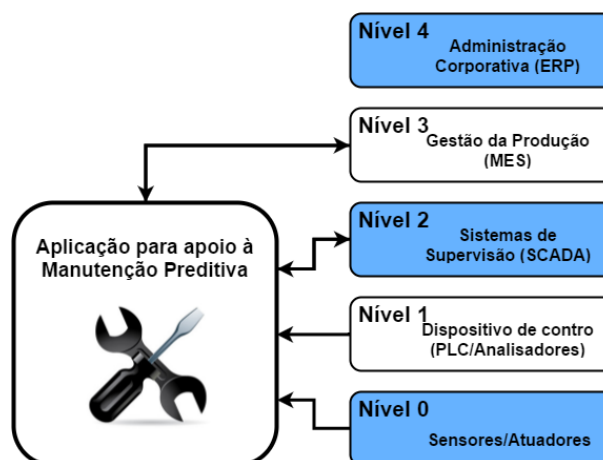


Figura 4.1: Representação da posição da solução proposta.

Numa fase inicial, é interessante começar por desenvolver pequenas aplicações SCADA, utilizando o *Movicon* e explorando as suas potencialidades. Este permite a comunicação, com recurso a vários tipos de protocolos de comunicação, uns específicos para autómatos *Siemens*, *Vipa*, *Omron*, outros ,como por exemplo *Profibus*, *modbus TCP/IP*, que se aplicam em diversos equipamentos de monitorização.

Consoante os equipamentos disponíveis, procurou-se encontrar os ideais para aplicar na análise de funcionamento de um equipamento. Assim foi escolhido o autómato *VIPA Slio 015* e um analisador de energia *Janitza UMG 604*, que permitirão garantir uma análise térmica a partir de sensores de temperatura, conectados ao autómato e uma análise elétrica. Relativamente à análise das vibrações, foi utilizado um sensor piezoelétrico, no entanto, este não apresentou desempenho suficiente que garantisse uma análise precisa.

Ambos os dispositivos selecionados comunicam por TCP/IP; para o autómato utiliza a configuração S7 TCP, para assim aceder a entradas e saídas de forma compatível com a programação em STEP7. Relativamente ao analisador de potência, este comunica por *modbus TCP/IP*, sendo necessário apenas que se defina o endereço da variável a supervisionar, consultando o *datasheet* do equipamento, quando este se encontrar devidamente configurado. Fisicamente, estes equipamentos conectam-se por *ethernet*, utilizando um *switch* que permitirá ter ambos os equipamento sincronizados com o computador.

Após ter desenvolvido as aplicações e otimizado as comunicações, procede-se à escolha do equipamento que será utilizado para testes de manutenção. É essencial que seja um equipamento que, à escala de um laboratório, seja logisticamente possível manusear e ao mesmo tempo significativo numa linha de produção.

Um motor elétrico, assíncrono trifásico, é a escolha ideal. É o mais usado de todos os tipos de motores, presente na maioria das linhas produtivas industriais, já que é de baixo custo, é de fácil transporte e simplicidade de comando.

Seguidamente, uma vez criada a aplicação SCADA, selecionados e configurados os equipamentos e sensores, o processo encontra-se apto para monitorizar eletricamente e termicamente,o motor selecionado, restando apenas guardar o histórico dos valores registados. Para tal, propôs-se a utilização de uma base de dados em *MySQL*, cuja comunicação, com a aplicação *Movicon*, é feita por ODBC (*Open Database Connectivity*) *driver/conector* .

Feita a monitorização do motor funcional e armazenados os dados, segue-se a análise e processamento dos mesmos que será executada a partir do *software Matlab*. Este *software* dispõe de inúmeros e poderosos modelos de previsão, com a aplicação de algoritmos de previsão de séries temporais a partir de redes neuronais. Como foi referido no capítulo 3.2.2, existem inúmeras formas de realizar previsões a partir desta ferramenta, que terá como objetivo a previsão da possibilidade de ocorrência de sobreaquecimentos no motor, avaliando o seu desempenho nos vários métodos, com recurso às redes neuronais.

Concluída esta descrição de funcionamento, estão reunidas todas as condições para for-

mular um esquema da solução proposta que pode ser observada na figura 4.2.

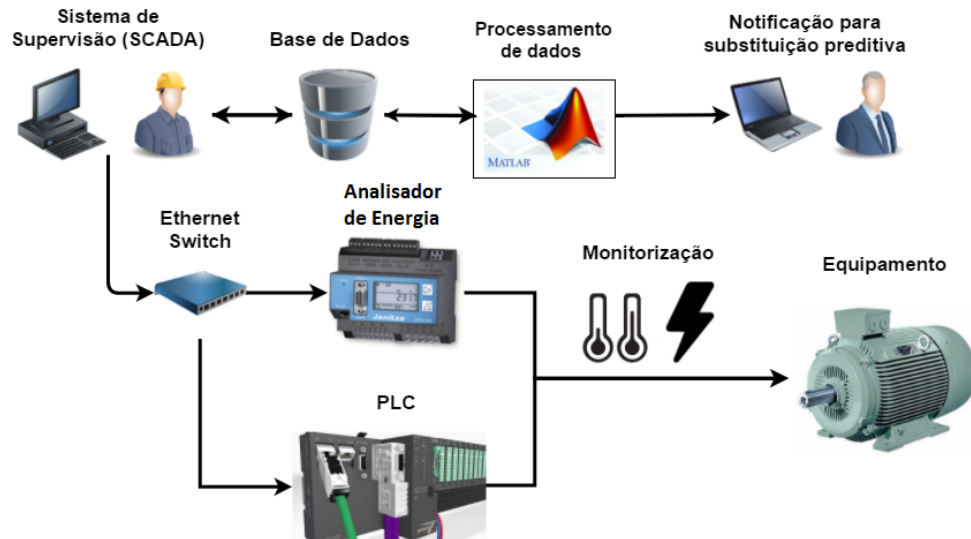


Figura 4.2: Arquitetura Geral da Solução Proposta.


4.1.2 Escolha da solução

De acordo com o estudo da literatura existente e tendo em consideração os dispositivos disponíveis em laboratório, foram testadas várias configurações tendo sido esta a solução que melhor resultados apresentou.


Várias metodologias foram exploradas, nomeadamente, a aplicação de um variador e a utilização de um sensor piezoelétrico para a análise de vibrações, como anteriormente foi referido. Contudo, analisador disponível apenas mede a energia na gama de frequência de 50Hz ou 60Hz, dado que, os valores registados noutra frequência não eram credíveis, o que inviabilizou a utilização do variador. Relativamente ao sensor piezoelétrico cujo objetivo era proceder à análise de vibrações, não foi possível garantir um isolamento suficiente, uma vez que, graças a um osciloscópio, detetaram-se imensas interferências eletromagnéticas que comprometeram a nitidez dos sinais.

A programação dos equipamentos era inicialmente realizada com auxílio de fontes de tensão para garantir que se encontravam bem configurados, conforme se pode notar nas figuras 4.3a e 4.3b que apresentam as ligações de uma fase de teste da ligação do variador com o motor.

No capítulo seguinte serão abordadas, de forma sucinta, as aplicações e a montagem do *hardware* e do *software* desenvolvido utilizados na solução escolhida.



(a) Variador Mitsubishi D700 SC



(b) Primeiros testes

Figura 4.3: Primeiros testes para o desenvolvimento e escolha da solução.

4.2 Implementação

A implementação deste protótipo será descrita em duas partes; a primeira consistirá na abordagem a todo o *hardware* selecionado, enquanto que na segunda proceder-se-á à explicação das interações entre *software*, bem como o seu desenvolvimento.

4.2.1 Hardware

Tendo sido, desde o início, o intuito desta dissertação encontrar uma solução de apoio à manutenção preditiva, orientou-se o estudo na procura de uma previsão para a evolução da temperatura de um motor elétrico, no sentido de antever irregularidades que servissem de alerta para sintomas de funcionamento incorreto. Todavia esta investigação foi limitada pelo facto de ocorrer apenas em contexto laboratorial.

Neste protótipo, o motor elétrico foi acoplado a uma passadeira de rolos, representativa de uma eventual linha de produção. Além disso, foi também construído um quadro elétrico com todos os equipamentos de análise, garantindo assim organização, segurança e condições de funcionamento.

A figura 4.4, à esquerda, apresenta o quadro elétrico com a identificação de cada constituinte. Na área 1, encontram-se os disjuntores, na 2 a fonte de alimentação para o autómato, na 3 o analisador de corrente, na 4 o PLC e na 5 o *ethernet switch*.

Esta mesma figura, à direita, apresenta o motor utilizado nos testes de forma a simular a sua função num processo produtivo, que, neste caso, possibilita o transporte de produtos ou matéria prima.

Nos subcapítulos seguintes, falar-se-á detalhadamente de todos os elementos constituintes.




Figura 4.4: Demonstração do hardware da solução.

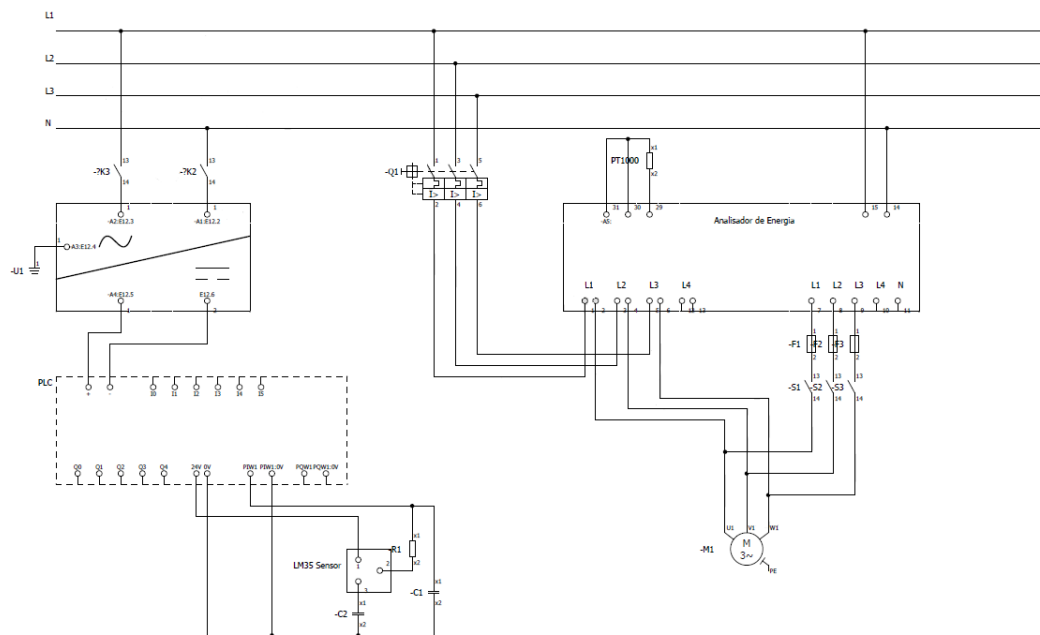


Figura 4.5: Esquema elétrico produzido no software EPLAN.

4.2.1.1 Aquisição de Temperatura

A configuração ideal para este tipo de análise é a avaliação da temperatura a partir de uma câmara termográfica ou então de um motor com sensores internos integrados no rotor ou na zona dos rolamentos, uma vez que é, nesta zona, que ocorrem a maioria das avarias.

No entanto, esta metodologia não pôde ser posta em prática por inexistência do equipamento necessário, tendo-se optado então por explorar soluções mais económicas, mas igualmente eficientes.

Nesta análise, utilizou-se dois sensores externos, um colocado em contacto com o motor e um outro situado na sua envolvente. Nas figuras 4.6a e 4.6b, encontram-se os dois sensores o PT1000 e o LM35, respetivamente. Escolheu-se o PT1000 para monitorização da temperatura do motor uma vez que este apresenta uma precisão superior ao LM35 e ausência total de ruído, sendo que este parâmetro é o mais relevante e central neste estudo.




Figura 4.6: Sensores de temperatura utilizados.

Como o sensor LM35 apresentou demasiado ruído, influenciando as medições, surgiu a necessidade da criação de um pequeno filtro para que a tensão gerada tivesse mais estabilidade, no entanto a criação desta configuração fez com que a resposta do sensor tivesse algum atraso. Porém, conseguiu-se encontrar um equilíbrio entre a estabilidade do sinal e o seu tempo de resposta.




Figura 4.7: Sensor LM 35 e PT1000 com respetiva implementação.

Recorrendo ao *datasheet* do sensor LM35 [58], verificou-se que se trata de um dispositivo

ideal para aplicações remotas. A gama de alcance da temperatura varia dos 2°C até aos 150°C, sendo um sensor linear com um fator de escala de +10mV/°C, que opera com uma alimentação que pode ir de 4 V até 30 V DC, com uma ampla gama de tensão, que se torna numa característica interessante e permite a sua alimentação diretamente a partir do autómato. Além disto, apresenta uma precisão de $\pm\frac{1}{4}^{\circ}\text{C}$ à temperatura ambiente e $\pm\frac{3}{4}^{\circ}\text{C}$ ao longo da gama das temperaturas que é capaz de medir.

Relativamente ao PT1000 do tipo ESMB-12, designado como um sensor universal [59] é um sensor de platina resistivo positivo com 1000 Ω a 0°C, cuja medição é não linear, com uma tolerância de 0,5°C na gama dos 0 aos 100 °C, convertido pelo analisador de potência.

4.2.1.2 Analisador de Potência

Para analisar as características elétricas é utilizado o Janitza UMG 604 que faz a análise a cada fase do motor. Para além de analisar parâmetros elétricos, também permite a aplicação de um sensor de temperatura. Aproveitando esta característica, utiliza-se um sensor PT1000 para monitorizar um parâmetro de temperatura a partir deste equipamento. Em termos de implementação, através da figura 4.8, verifica-se que a ligação do sensor é relativamente fácil. Este só dispõe de 2 cabos no entanto, o equipamento apenas realiza medições com 3, assim, para superar este obstáculo, resolveu-se ligar o pino 30 ao 31 colocado em paralelo com o sensor, conforme é apresentado na figura.




Figura 4.8: Implementação do Sensor de PT1000 adaptado de [60].

Para melhor apreender o procedimento das restantes ligações, representadas na figura 4.9, consultou-se o *datasheet*[60] do equipamento que indica que este necessita de conectar-se em paralelo com o neutro da alimentação, fase 1 (L1), fase 2 (L2) e fase 3 (L3) nos pinos 13, 9, 10 e 11, respetivamente. Ao mesmo tempo, são feitas também conexões colocadas em série com a alimentação, tornando-se imperativo que as respetivas fases do motor estejam concordantes com as que o equipamento está a medir. Quer isto dizer que é fundamental ter as fases do equipamento corretamente identificadas, já que a troca de ligação faz com que os valores medidos estejam totalmente errados.

Embora a figura 4.9b, que foi retirada do *datasheet* do Janitza, aconselhe a utilizar trans-

formadores de corrente, na prática não foi possível utilizá-los. Um transformador de corrente é um dispositivo capaz de reproduzir, num circuito secundário, a corrente que circula no enrolamento primário, ou seja, a corrente que passa em cada fase do motor é reproduzida num circuito à parte, garantindo assim segurança na instalação. No entanto, como se fala de corrente inferior a 6 amperes, pode-se dispensar a sua utilização, ligando diretamente em série, o que garante, da mesma, forma uma medição correta, dado que no dispositivo, "a medição de corrente poder ser permanente com ligações até 6 A ou por 1 segundo a 100A" [60].

Como o motor em estudo possui de uma configuração em estrela, consequentemente, não possui neutro, assim coloca-se em série apenas com as respetivas fases de alimentação.




Figura 4.9: Configuração para analisar a alimentação do motor adaptado de [60].

Finalmente, para receber e processar os dados, o mesmo dispõe de uma porta *ethernet* possibilita a comunicação por *modbus* com o computador.

Findo o processo de ligação, resta apenas configurar o equipamento que é possível de duas formas. Uma no próprio equipamento, já que este está dotado de um pequeno ecrã no qual é possível verificar as suas configurações (este método é pouco prático sendo essencial apenas para definir o IP do equipamento). A outra forma é aplicada quando está disponível uma ligação com o computador utilizando o *software GridVis 7.1* que permite a configuração total do equipamento de forma mais intuitiva. Todo este processo de configuração será abordado na subsecção 4.2.2.

4.2.1.3 Motor Elétrico

O motor elétrico utilizado é trifásico assíncrono com a chapa de características representada na figura 4.10. Trata-se de um motor de 0.18 kW ou 0.25 HP (Horse Power) de potência cuja ligação em estrela deverá ter uma diferença de potencial entre fases de 380V, enquanto que em triângulo deverá estar por volta dos 220V. Estes valores já não se verificam, uma vez que a tensão da rede foi aumentada ao longo dos anos, estando atualmente nos 230 em cada

fase, resultando assim numa diferença de fases entre 390 a 400 V. Em termo de corrente, verifica-se 0,6 amperes para a ligação em estrela e 1,0 ampere para a ligação em triângulo. Além disso, o motor tem um fator de potência ($\cos\varphi$) de 0,75, do tipo IP54, que indica o grau de proteção que é apresentado na norma NBR IEC 60529¹ que refere os graus de proteção para invólucros de equipamentos elétricos. O primeiro dígito do IP refere-se à proteção contra pó e o segundo dígito identifica a proteção contra a humidade.



Figura 4.10: Chapa de características do motor elétrico.

Uma vez apresentados os valores da chapa de características, pretende-se provar que o analisador tem as conexões feitas de forma correta e se encontra devidamente configurado. Para isso, comparam-se os valores referidos com os registados. Nas figuras 4.14 e 4.12 é possível verificar que, de facto, os valores correspondem, estando o fator de potência com maior desvio, o que se justifica pelo facto de o tapete rolante criar alguma carga, aumentando a potência reativa o que, conseqüentemente, aumentará o valor do ângulo φ reduzindo o seu cosseno.



Figura 4.11: Valores reais de corrente e voltagem registados.

¹Norma consultada a 29-06-2016 em <http://www.rittal.com/pt-pt/content/pt/support/technischeswissen/qminformiert/schutzarten/ip/ip1.jsp>.




Figura 4.12: Relação Potência e Fator de Potência.

4.2.1.4 PLC

O PLC utilizado é da marca VIPA Slio com CPU 015 tendo sido utilizado para vários propósitos. Numa fase inicial logicamente começa-se pela sua configuração, identificando as cartas de entrada/saída e ligações, já que se trata de um dispositivo que comunica por *profinet*. Foram feitos vários testes, programados para controlar o motor elétrico com auxílio de um variador que possibilitou alterar a sua velocidade através da frequência; inverter o sentido de rotação; ligar/desligar o motor; entre outros. Porém, o facto de variar a frequência não permitiu ter uma avaliação direta com o analisador de energia, uma vez que este só opera com uma frequência de 50 ou 60 Hz. Deste modo, optou-se por retirar o variador e faz-se as medições diretamente. Não podendo utilizar o variador, o autómato apenas processou a monitorização da temperatura da envolvente do motor.




Figura 4.13: PLC Vipa Slio 015.




Figura 4.14: Estrutura autômato.

Tabela 4.1: Legenda da figura 4.14

1	Patilha para fixar o autômato à calha
2	Slot para armazenamento externo a partir de um cartão de memória
3	Led que indica o estado em que se encontra o CPU
4	Etiqueta para modulo de alimentação do CPU
5	LED que indica o estado do modulo de alimentação
6	Conector <i>bus</i> para os outro módulos
7	Secção 24V DC do modulo de alimentação
8	Patilha para desmontar a parte superior do modulo
9	Interface traçado para <i>Profinet</i>
10	Para traçado para o canal Ethernet PG/OP
11	Interface PtP(MPI) RS485
12	Interface MPI(PB) RS485
13	LED que indica o estado da conexão do controlado <i>Profrinet IO</i>
14	Interruptor para o modo de operação do CPU
15	Parte do CPU
16	Terminal do modulo de alimentação

O equipamento dispõe de 7 cartas, uma para alimentação do CPU, outra apenas para alimentação de periféricos, duas de entrada digital, uma de entrada analógica, uma de saída digital e outra de saída analógica, operando a 24v nas digitais e de 0 aos 10V nas analógicas.

Assim sendo, será colocado, numa das entradas analógicas do autômato, o sensor LM35 (ver subcapítulo 4.2.1.1) que monitorizará a temperatura, ligado-se da forma que está indicada na figura 4.15. A alimentação do sensor dos dois fios mais à esquerda é feita através do azul, ligado aos 24v fornecidos pelo autômato, e do vermelho, ligado aos 0 V. A tensão produzida pelo sensor (V_{out}) é a diferença de potencial do pino 1 com o pino 5, em que este último está

conectado à terra do sensor. Os pinos 1 e 5 pertencem à carta de entradas analógicas.

A programação do autômato será descrita no subcapítulo 4.2.2.1.




Figura 4.15: Esquema ligação sensor temperatura a uma entrada analógica do autômato.

Tabela 4.2: Legenda da figura 4.15

1	Modulo de alimentação
2	Modulo de entrada digital 021-1BD00
3	Modulo de entrada digital 021-1BF00
4	Modulo de alimentação 24V/0V
5	Modulo de saída digital 022-1BD00
6	Modulo de entrada analógica 031-1BB30
7	Modulo de saída analógica 032-1BB30

4.2.2 Desenvolvimento e configuração de software

Toda a explicação do *software* será abordada de forma idêntica à secção anterior, começando por uma abordagem geral e posteriormente a casos em particular. Assim, a figura 4.16 apresenta um fluxograma de toda a função, desde a aquisição dos dados até à sua análise e previsão.

No total, o protótipo suporta-se em três *software*, o *Movicon*, a base de dados do *MySQL* e o *Matlab*. O primeiro, a aplicação *SCADA*, é responsável pela supervisão e aquisição dos dados, em *MySQL* tem-se a base de dados que armazena as variáveis monitorizadas servindo de ligação entre os outros dois *software*, por fim o *Matlab* realiza o tratamento dos dados e a criação da rede neuronal, calculando os valores previstos.

O utilizador apenas necessita de utilizar o HMI (interface homem máquina) em *Movicon*, dado que este tem códigos desenvolvidos em VBA (*Visual Basic Application*) que, a pedido do utilizador, executa a previsão dos dados automaticamente, correndo em segundo plano uma aplicação criada em linguagem *Matlab*.

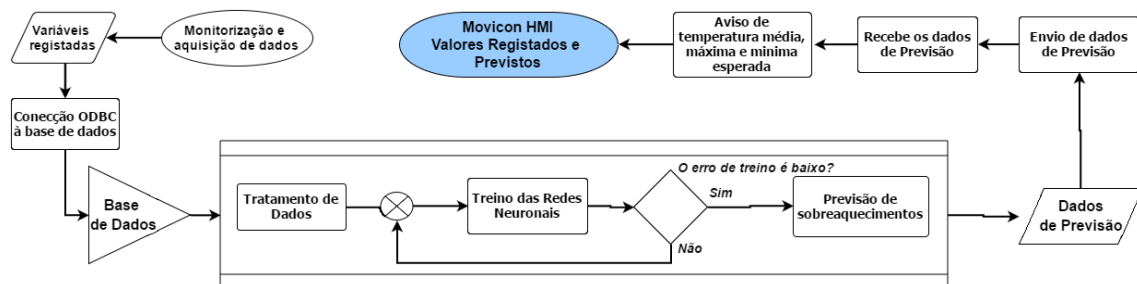


Figura 4.16: Fluxograma do software implementado na solução proposta.

4.2.2.1 Programação PLC

Como referido em capítulos anteriores, o PLC utilizado na solução é da marca VIPA Slio com o CPU 015. A sua configuração/programação é feita a partir do Simatic STEP 7 da Siemens sendo também compatível com o TIA Portal. Estes *software* são os mesmos que são

utilizados na programação dos autômatos da marca *Siemens*, já que este CPU corresponde aos PLC S-300.

A sua programação tem como foco principal uma função construída em blocos de funções (*Function Block*) que é responsável pelo processamento e conversão da tensão que o sensor causa na carta de entrada analógica. A mesma rege-se segundo o fluxograma apresentado na figura 4.22. Além da função, é colocado o valor de entrada numa memória *word* que servirá de input para a mesma.

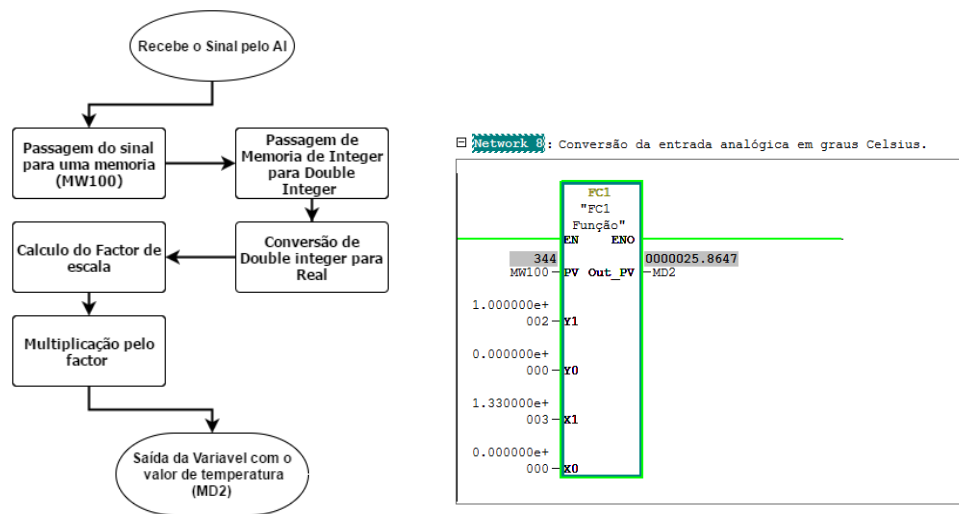


Figura 4.17: Fluxograma e função de conversão dos dados recebido pelo sensor.

Esta função está apresentada na figura 4.22 e possui quatro variáveis de entrada, que resultam numa outra de saída com o valor de temperatura em graus centígrados. A primeira variável de entrada é o MW100, trata-se da memória que contém o valor resultante da conversão A/D (analógica/digital), tendo em seguida Y1 e Y0, que são os parâmetros limites da conversão para graus centígrados, e por fim, X1 e X0 que representam os valores da conversão A/D.

A entrada analógica do autômato pode receber um sinal que varia de 0 a 10V, cuja conversão A/D contém uma resolução de 12 bit. Assim, como o sensor varia de 0.01 mV/°C e sabendo que a 25°C produz uma voltagem de saída de 0.250 mV [58], concluiu-se que para 100°C ter-se-á na entrada analógica aproximadamente 1 V e da mesma forma para 0°C verificar-se-á 0V. Seguindo esta lógica e com o auxílio de uma fonte de tensão ligada à entrada analógica colocando-a a 1V, simulando que o sensor esteja 100°C, foi assim possível retirar o valor da conversão A/D correspondente.

Utilizando este método foi possível definir o valor de X1 e X0 para a função e assim calibrar o sensor.

Dentro da função, acontecem as etapas apresentadas pelo fluxograma, a mesma converte o tipo de variável, calcula o fator de escala, multiplica o sinal por esse fator, resultando assim

na variável MD2 que contém já o sinal convertido em graus celsius. No apêndice A.3 é possível ver o funcionamento detalhado desta função.

É importante referir que foi feita uma simulação no *software* ISIS do sensor com o filtro que lhe foi aplicado para reduzir o ruído, e verificou-se que o sensor não sofre alterações na voltagem. Apenas se constatou um ligeiro aumento do atraso da resposta às variações de temperatura, podendo assim utilizar os valores de conversão apresentados no *datasheet* do equipamento.

4.2.2.2 Configuração Janitza UMG604

Como dito em 4.2.1.2, configurou-se a analisador de energia, definindo apenas o IP no próprio equipamento e utilizou-se o *software* GridVis 7 para a restante configuração. Para além de permitir a configuração do equipamento este *software* é também uma espécie de SCADA, desenvolvida pelos fabricantes da marca, específica para este tipo de equipamentos. Permite a monitorização das variáveis em tempo real, criação de alarmes, leitura e escrita em bases dados, configuração, colocação de múltiplos equipamentos em simultâneo, entre outros.

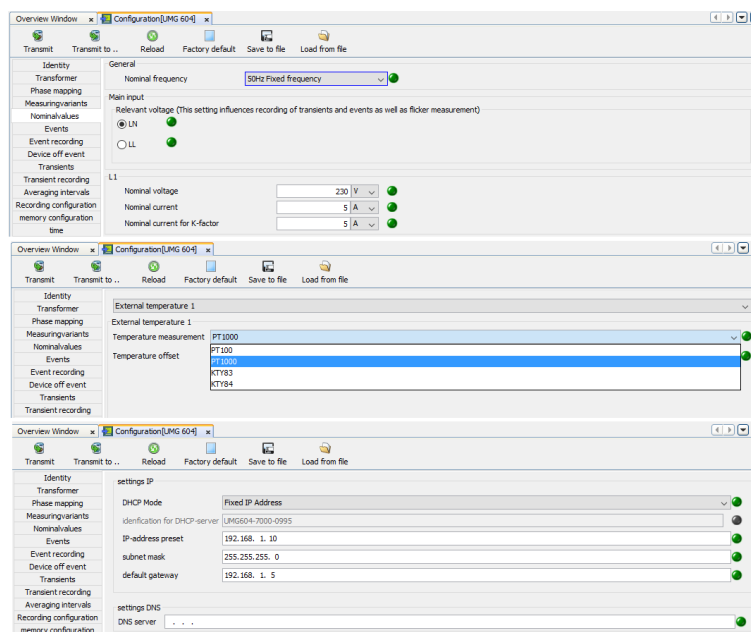


Figura 4.18: Configuração de alguns parâmetros.

O módulo de configuração aliado à consulta do *datasheet* do equipamento permitiram uma aprendizagem rápida do seu funcionamento. Nele podem ser feitas configurações para escolher qual o tipo de sensor de temperatura a instalar no equipamento, configurações do IP, a variante de medição, se é uma medição a 3 cabos (L1, L2 e L3) ou a 4 cabos (L1,L2,L3 e N), quais as fases dos dispositivos que correspondem às conectadas no analisador, entre

outros. Na figura 4.18, é possível visualizar parte de algumas configurações, das quais, a primeira define parâmetros característicos da rede elétrica, escolha do sensor e definição do IP, respetivamente.

4.2.2.3 MatLab

Para a construção de um modelo de previsão baseado nas Redes Neurais, recorreu-se às poderosas ferramentas matemáticas de que o *software Matlab* dispõe.

A aplicação criada em *Matlab* será integrada à do *Movicon*, sendo utilizada quando houver pedido por parte do utilizador e correrá, em tempo real, a previsão do comportamento da temperatura.

Na figura 4.19, é possível ver o fluxograma do programa. Começa por aceder à base de dados e reter os valores de input, que podem ser a corrente, a voltagem, a potência ou a temperatura ambiente. Estes são seleccionados consoante o método utilizado, colocando numa matriz em que cada coluna corresponde a um parâmetro de input. Da mesma forma é retirado o output sendo este apenas a temperatura do motor registada pelo sensor PT1000, pois é este parâmetro que se pretende prever.




Figura 4.19: Método NARX e NAR.

Segue-se o pré-processamento de dados que consiste na conversão e normalização dos inputs para um intervalo de $[0;1]$, preparando-os assim para o treino da rede. O método de treino utilizado será o algoritmo Levenberg-Marquardt. Desta forma a rede será treinada ciclicamente até atingir um erro de treino suficientemente baixo, deixando a rede preparada para prever.

Existe a possibilidade de o utilizador escolher um de três métodos de aplicação das redes neurais: um com um processo não linear autorregressivo (NAR), um outro não linear autorregressivo com um *input* externo (NARX) e por fim um NARX com vários inputs externos².

Para o método NAR são apenas utilizados os valores de *target* conforme apresentado na figura 4.20, à direita, neste caso os valores de temperatura registados anteriormente são utilizados no treino da rede e consoante esse comportamento a rede prevê os valores de temperatura

²Para mais explicação de séries não lineares auto-regressivas consultar o sub-capítulo 3.1

seguintes. O segundo e terceiro métodos utilizam o NARX, funcionando de forma idêntica tendo além de parâmetros alvo (*target*) também parâmetros externos de entrada (*inputs*). Será abordado de duas formas, uma em que a rede é treinada com apenas um parâmetro de entrada, por exemplo, a corrente, com o respetivo valor alvo correspondente, neste caso a temperatura. A segunda forma utilizará vários valores de entrada, como corrente, voltagem e potência, com os respetivos valores alvo da temperatura do motor. Este método prevê os valores de temperatura a partir de novos parâmetros externos. Posto isto, serão abordados diferentes métodos de previsão elaborando mais adiante, no capítulo 5.1, uma análise dos resultados que procurará verificar a sua eficiência.

Esta aplicação pode ser utilizada de duas formas, uma para o caso do utilizador usufruir do *software Matlab* e outra em forma de aplicação, tendo sido criado um executável, permite instala-lo em qualquer outro computador. Para o segundo caso, a aplicação é um executável, não sendo necessário recorrer ao *Matlab* e apresenta o interface da figura 4.21. A rede já sofreu um pré-treino, ou seja não é treinada sempre que se pretende simular, enquanto que na forma que utiliza o *software Matlab* esta é treinada sempre que o pedido de simulação é efetuado.

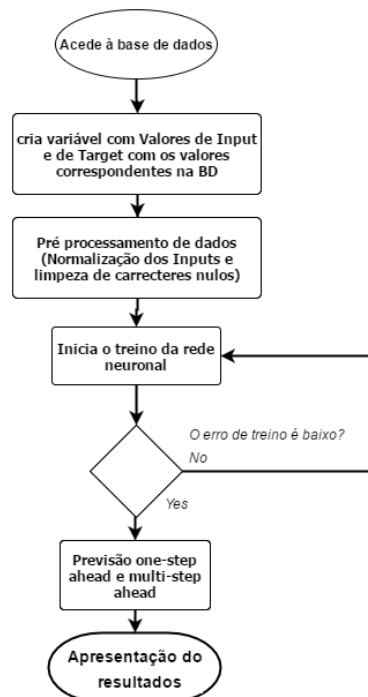


Figura 4.20: Fluxograma da aplicação das Redes Neurais.

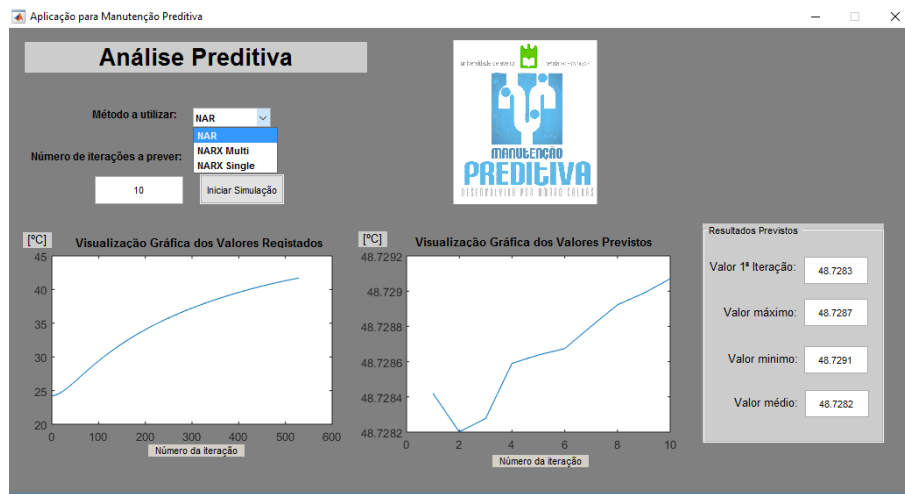


Figura 4.21: Interface aplicação.

Ao correr a aplicação, é apresentado a interface da figura 4.21 que permite iniciar a simulação. O utilizador começa por indicar o método a utilizar e o número de iterações que pretende simular, bem como a possibilidade da escolha do ficheiro com a rede neuronal treinada que melhor de adequa, resultando na representação gráfica dos valores previstos e de histórico, bem como valor médio, máximo, mínimo e o da primeira iteração. Caso o utilizador não preencha os campos necessários, é avisado com mensagens de erro, o que possibilita uma fácil utilização e garante que a aplicação está a ser bem utilizada.

4.2.2.4 Movicon

Como referido no capítulo 2.3.2, o *Movicon* é um software SCADA desenvolvido pela Progea, a versão 11 é a utilizada no desenvolvimentos desta solução. Tem como principal função a supervisão e aquisição de dados, além disto oferece a possibilidade de criação de vários HMI (Interface Homem Máquina), para que o operador seja capaz de facilmente consultar o estado em que se encontram os equipamentos a ser monitorizados. É também responsável por registar variáveis em base de dados, criando assim um histórico de parâmetros essenciais na manutenção dos equipamentos e a partir dos quais será feito o estudo.

Além disso, garante um fluxo de informação em tempo real entre os vários setores de uma empresa, mesmo numa empresa de grandes dimensões.

Esta aplicação foi criada com o objetivo principal de monitorizar as entradas e saídas do PLC, registar os valores dados pelo analisador de corrente e demonstrar os valores de temperatura previstos.

A nível visual, é constituído por 5 ecrãs (HMI), um principal que mostra a configuração do equipamento, a ativação de saídas do autómato, a avaliação de dados e o histórico, a representação gráfica do comportamento das variáveis e a gestão de alarmes; um outro ecrã contém a visualização das variáveis a serem monitorizadas pelo analisador elétrico; um terceiro com

a parte de manutenção preditiva em que podem ser utilizados os 3 métodos diferentes de previsão; um quarto em que é possível analisar todas as variáveis a monitorizar graficamente, podendo ser analisado todo o histórico; e por fim um ecrã dedicado à monitorização da temperatura, representando as mesmas graficamente à medida que são registadas. Todos estes ecrãs podem ser observados na figura 4.22.

O código em *Matlab* com o algoritmo de previsão é ativado sempre que utilizador na janela de manutenção preditiva 4.22c dê ordem para que o *software* avalie os dados até ao momento que se encontra, ou seja sempre que clique no botão "*iniciar previsão a partir do Matlab*", é acionado um *script* desenvolvido em VBA que inicia a aplicação *Matlab*, correndo o respetivo código desenvolvido para o efeito. Após alguns segundos de processamento o utilizador visualiza o comportamento previsto graficamente e no ecrã do *Movicon* são mostrados os valores máximo, mínimo e médio previstos da temperatura do motor. Em contrapartida, se o utilizador não tiver o *Matlab* instalado no computador pode optar por simular a partir da aplicação criada. Como referido na subsecção anterior 4.2.2.3, trata-se um executável que uma vez instalada esta inicia sempre que o botão "*iniciar aplicação*" for premido, apresentado a sua interface (figura 4.21).

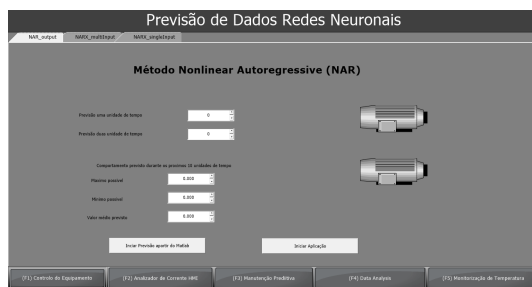
Em suma, o utilizador, a partir da aplicação criada em *Movicon*, tem acesso a parâmetros elétricos e de temperatura em tempo real, bem como ao seu histórico e ainda consegue prever o comportamento da temperatura do motor.



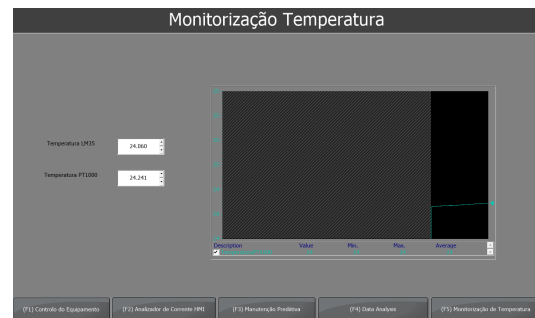
(a)



(b)



(c)



(d)



(e)

Figura 4.22: Grafismo apresentado pela aplicação SCADA.

4.2.2.5 MySQL

A base de dados será responsável pela organização e armazenamento de dados para serem acedidos pelos dois softwares (*Movicon* e *Matlab*).

Em *Mysql* existe a possibilidade da criação de vários utilizadores que podem ser distinguidos de acordo com os privilégios de acesso, determinados pelo administrador; além disso, é possível proteger o acesso com *password* para garantir alguma segurança. A criação das tabelas para armazenamento pode ser feita manualmente ou através de programas externos, como é o caso do *software Movicon*. Acresce ainda a possibilidade de aceder às aplicações em qualquer dispositivo, não necessitando de grande capacidade de memória sendo o servidor

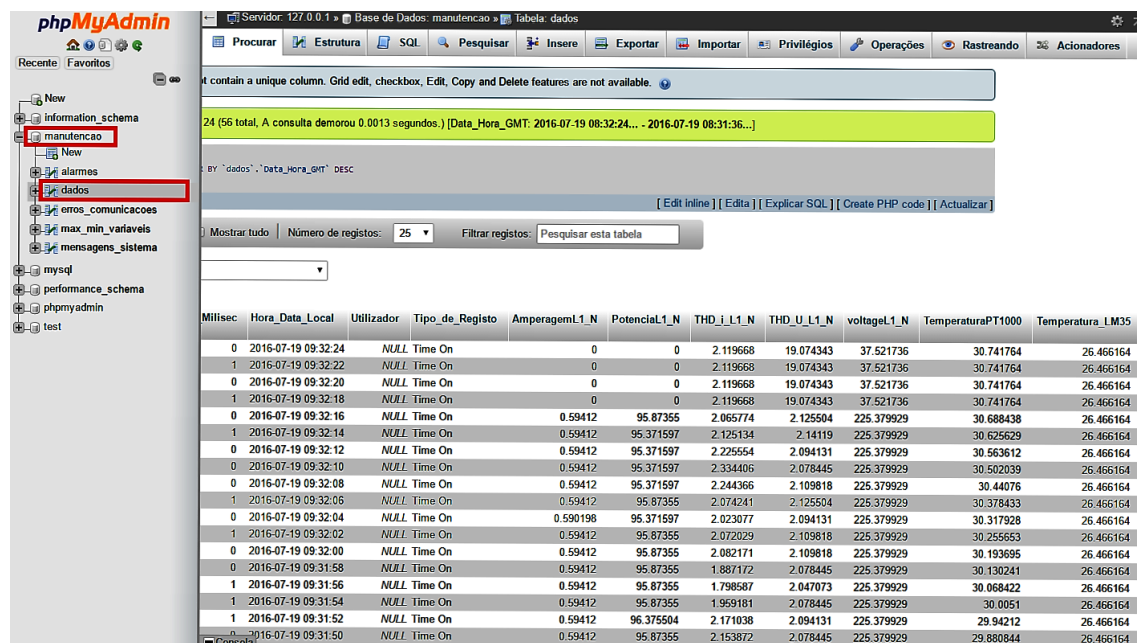
responsável por gerir e armazenar a informação partilhada na rede.

A manipulação de tabelas pode ser feita através do *MySql Workbench* ou a partir do *phpMyAdmin*.

Para aceder à base de dados a partir de outras aplicações, recorre-se a uma ligação por ODBC e a partir dela acede-se com um perfil de utilizador. Para tal, foi criado um perfil através do *phpMyAdmin* com permissões de escrita e leitura que autoriza, a partir de um *software* externo a manipulação de tabelas, a inserção ou remoção de conteúdos.

Após a configuração e com a base de dados criada, verifica-se o resultado final na figura 4.23. A base de dados criada tem o nome de "manutencao" e é constituída por cinco tabelas: alarmes, dados registados em tempo real, erros de comunicação com os dispositivos, máximo e mínimo dos dados a monitorizar e mensagens de erro que possam ocorrer durante o funcionamento da aplicação. Estas tabelas estão colocadas na base de dados por esta ordem como apresentado na figura 4.23.

Para efeitos de teste, a base de dados está sediada em *LocalHost* e a tabela "dados" é composta por hora e data do registo com os respetivos valores das propriedades que estão a ser monitorizadas em tempo real.



The screenshot shows the phpMyAdmin interface with the 'manutencao' database selected. The 'dados' table is highlighted in the left sidebar. The main window displays the table structure and a list of 24 records. The records are sorted by 'Data_Hora_GMT' in descending order. The columns are: Milisec, Hora_Data_Local, Utilizador, Tipo_de_Registo, AmperagemL1_N, PotenciaL1_N, THD_i_L1_N, THD_U_L1_N, voltageL1_N, TemperaturaPT1000, and Temperatura_LM35.

Milisec	Hora_Data_Local	Utilizador	Tipo_de_Registo	AmperagemL1_N	PotenciaL1_N	THD_i_L1_N	THD_U_L1_N	voltageL1_N	TemperaturaPT1000	Temperatura_LM35
0	2016-07-19 09:32:24	NULL	Time On	0	0	2.119668	19.074343	37.521736	30.741764	26.466164
1	2016-07-19 09:32:22	NULL	Time On	0	0	2.119668	19.074343	37.521736	30.741764	26.466164
0	2016-07-19 09:32:20	NULL	Time On	0	0	2.119668	19.074343	37.521736	30.741764	26.466164
1	2016-07-19 09:32:18	NULL	Time On	0	0	2.119668	19.074343	37.521736	30.741764	26.466164
0	2016-07-19 09:32:16	NULL	Time On	0.59412	95.87355	2.065774	2.125504	225.379929	30.688438	26.466164
1	2016-07-19 09:32:14	NULL	Time On	0.59412	95.371597	2.125134	2.14119	225.379929	30.625629	26.466164
0	2016-07-19 09:32:12	NULL	Time On	0.59412	95.371597	2.225554	2.094131	225.379929	30.563612	26.466164
0	2016-07-19 09:32:10	NULL	Time On	0.59412	95.371597	2.334406	2.078445	225.379929	30.502039	26.466164
0	2016-07-19 09:32:08	NULL	Time On	0.59412	95.371597	2.244366	2.109818	225.379929	30.44076	26.466164
1	2016-07-19 09:32:06	NULL	Time On	0.59412	95.87355	2.074241	2.125504	225.379929	30.378433	26.466164
0	2016-07-19 09:32:04	NULL	Time On	0.590198	95.371597	2.023077	2.094131	225.379929	30.317928	26.466164
1	2016-07-19 09:32:02	NULL	Time On	0.59412	95.87355	2.072029	2.109818	225.379929	30.255653	26.466164
0	2016-07-19 09:32:00	NULL	Time On	0.59412	95.87355	2.082171	2.109818	225.379929	30.193695	26.466164
0	2016-07-19 09:31:58	NULL	Time On	0.59412	95.87355	1.887172	2.078445	225.379929	30.130241	26.466164
1	2016-07-19 09:31:56	NULL	Time On	0.59412	95.87355	1.798587	2.047073	225.379929	30.068422	26.466164
1	2016-07-19 09:31:54	NULL	Time On	0.59412	95.87355	1.959181	2.078445	225.379929	30.0051	26.466164
1	2016-07-19 09:31:52	NULL	Time On	0.59412	96.375504	2.171038	2.094131	225.379929	29.94212	26.466164
0	2016-07-19 09:31:50	NULL	Time On	0.59412	95.87355	2.153872	2.078445	225.379929	29.880844	26.466164

Figura 4.23: Janela das base de Dados.

Capítulo 5

Análise de resultados e considerações finais

5.1 Análise de Resultados

Os subcapítulos apresentados a seguir abordam um estudo comparativo dos resultados obtidos, da simulação com redes neurais, para dois casos de estudo. Serão avaliados desvios entre valores previstos e esperados, a um passo e a multi-passos à frente, tempos de processamento e respectivas conclusões sobre os respectivos desempenhos.

5.1.1 Metodologia de Análise

A análise de resultados será feita a partir da eficácia da previsão da temperatura que o sensor PT1000 regista, ou seja a temperatura do motor durante o arranque, com principal ênfase numa fase estacionária que ocorre após uma hora de funcionamento.

Devido à indisponibilidade de motores elétricos nos quais seja possível causar avarias, para assim se proceder ao estudo, procurou-se abordar o caso de uma outra forma, aplicando interferências no comportamento do motor a partir da manipulação de parâmetros externos, para avaliar deste modo, o desempenho do algoritmo. Os parâmetros externos são os que consideramos como valores de entrada para a rede neuronal, a saber, a temperatura ambiente, a corrente, a tensão, o fator de potência e a potência real. O parâmetro de saída considerado é a previsão da temperatura do motor. Estes atributos são registados na forma de série temporal em que cada iteração é feita de 2 em 2, segundos tendo um total de 2586 amostras, no caso de estudo 1, e 3086 no 2. A figura 5.1 apresenta graficamente a evolução dos valores registados da temperatura do motor para as duas situações em que o objetivo é prever a continuidade desta série. Assim, às amostras simuladas, retiraram-se os últimos valores (designados de valores esperados), de forma a confrontá-los com os previstos.

Os valores registados apresentam um comportamento inicial de tendência evolutiva cres-

cente da temperatura, uma vez que o motor está a iniciar o seu funcionamento ("fase de arranque"), atingindo a estabilidade, atingindo a fase que podemos considerar a "estacionária"; esta será a altura em que melhor se verifica a influência dos parâmetros externos, que serão o ponto central nesta análise.

Na observação da figura 5.1, destacam-se diferenças na evolução da temperatura do motor, dado que os parâmetros externos influenciaram o seu comportamento e estes foram manipulados de forma diferente em cada caso. No estudo 2, a variação da temperatura aumenta inicialmente de uma forma mais rápida, atingindo temperaturas superiores ao primeiro caso. Além disso, na fase estacionária os comportamentos são diferentes, sendo estas características objeto de análise de interesse superior.




Figura 5.1: Série Temporal da evolução da temperatura registada no caso de estudo 1 e 2, respetivamente.

A fim de interpretar e perceber os gráficos de temperatura e a razão destas diferenças, as figuras 5.3 e 5.2 apresentam graficamente as séries registadas dos parâmetros externos que influenciaram o seu desempenho. A rede neuronal terá deste modo estes valores como parâmetros de entrada e como parâmetros de saída, a temperatura do motor.

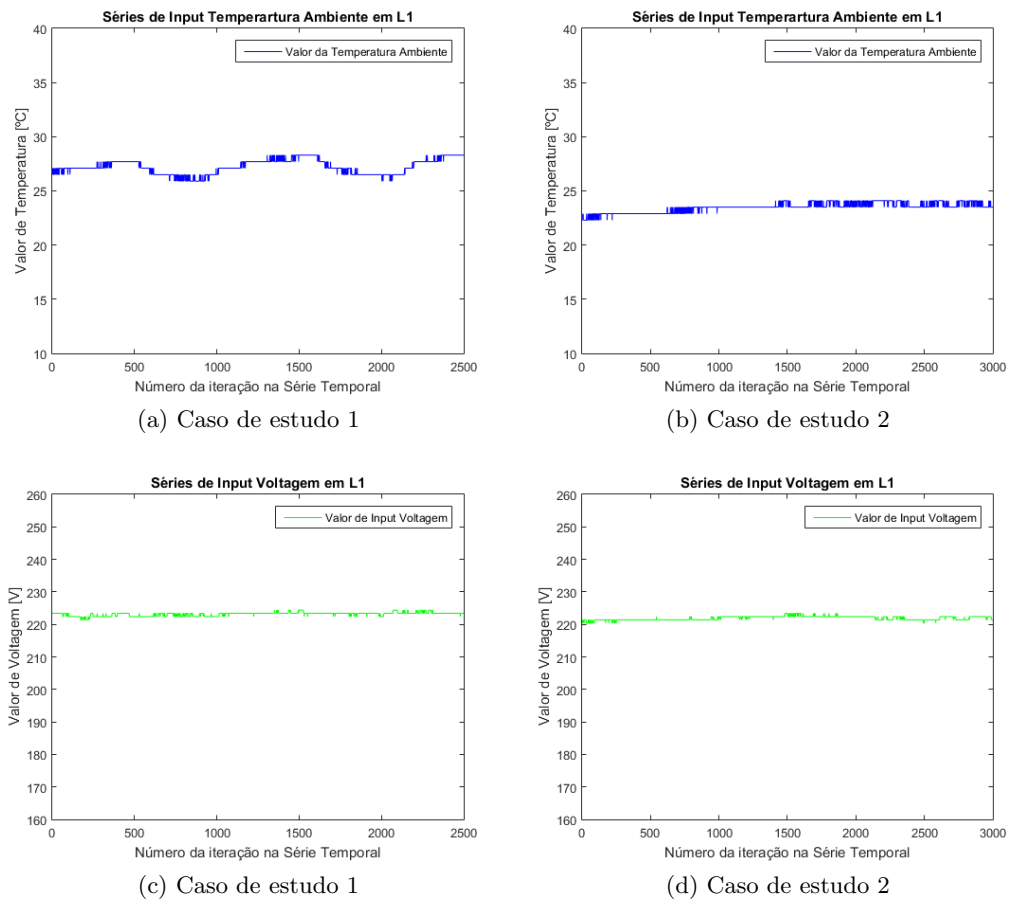


Figura 5.2: Séries temporais do valor de inputs em cada caso de estudo.

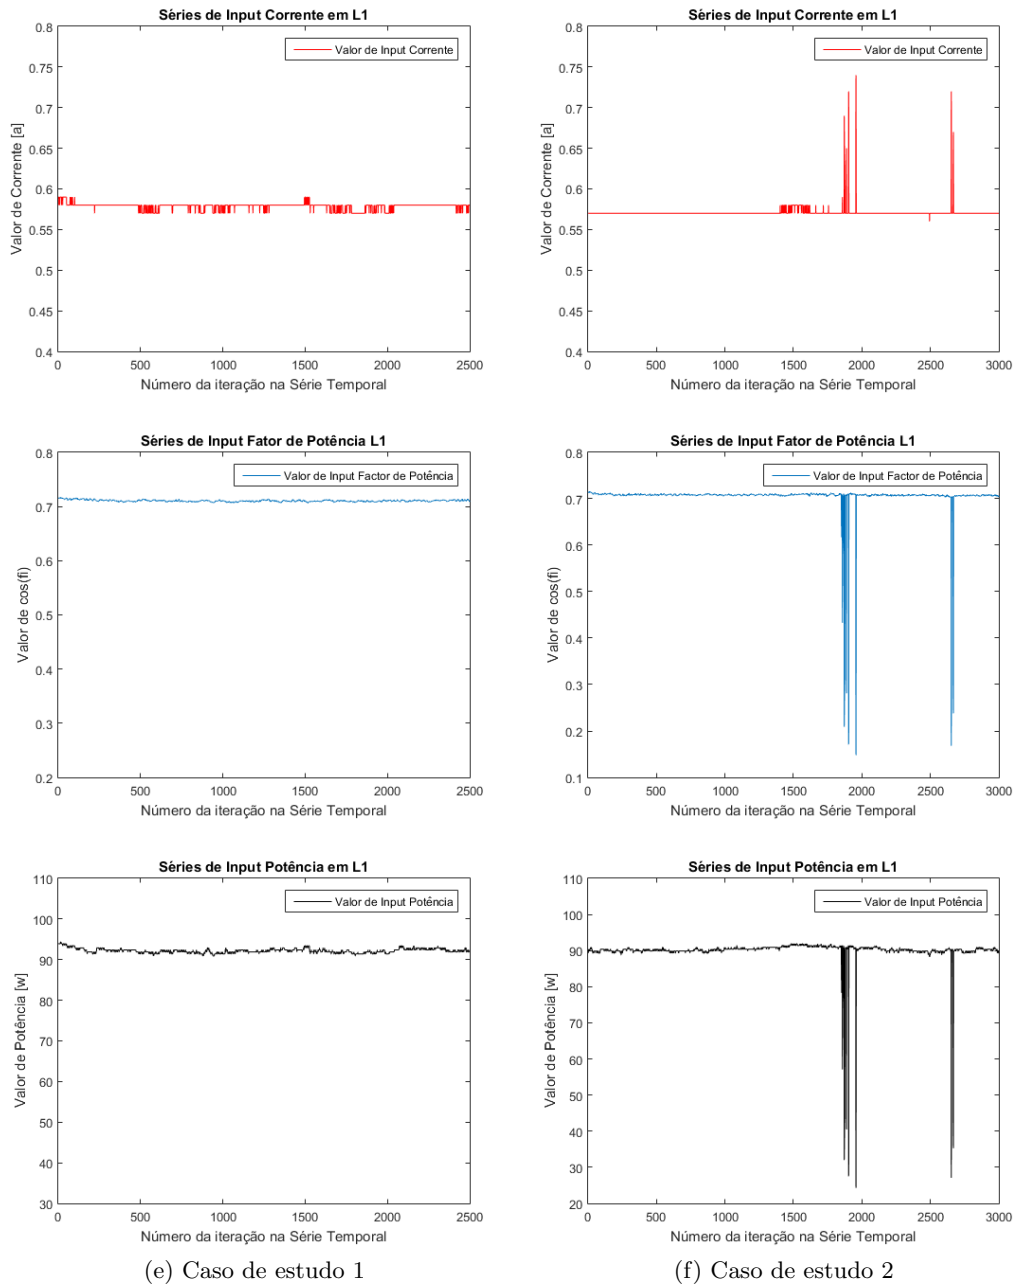


Figura 5.3: Séries temporais do valor de inputs em cada caso de estudo.

No caso de estudo 1, colocou-se o motor em funcionamento sem qualquer manipulação de parâmetros externos, exceto a temperatura ambiente. Esta variação não apresentou qualquer influência nos valores do fator de potência, potência e corrente.

No segundo caso, até à fase estacionária, não se produziu nenhuma interferência mantendo-se a temperatura ambiente estável. Chegando à fase estacionária, passou-se a aplicar cargas pontuais no motor, de modo a trava-lo, o que provocou alterações no fator de potência e

potência consumida pelo motor. A diminuição do fator de potência deveu-se ao facto do motor perder eficiência, uma vez que estava em esforço, o que causou um aumento da energia reativa que, conseqüentemente, aumentou a temperatura do equipamento. A corrente também aumentou, contudo a tensão não sofreu alterações significativas, dado que tratava de um motor de baixa potência que não deu lugar a quebras de tensão ou sobrecarga dos elementos da rede.

Para provocar sobrecarga no motor, travou-se o tapete rolante, a fim de esforçar o motor; a temperatura da sala foi mantida propositadamente inalterada.

Na figura 5.4, foi possível comparar a variação da temperatura ambiente com a do motor, estas variaram de forma idêntica, logo quando a temperatura ambiente subia a do motor também o fazia. A situação inversa também se verificou.

Para o segundo caso, observando os resultados na figura 5.5, conclui-se que os picos de queda de potência real foram causados pelo bloqueio do tapete, o que provocou um aumento da potência reativa e da corrente; por outro lado ocorreu a queda da potência real bem como do fator de potência. Ao criar estas sobrecargas, verificou-se em 5.5b que a temperatura do motor se elevava sempre que estes picos ocorriam, arrefecendo em seguida com tendência para a temperatura normal de funcionamento.




Figura 5.4: Relação entre temperatura ambiente e temperatura do motor para o caso de estudo 1.

No âmbito a arquitetura da solução proposta, foram escolhidos este casos de estudo, já que foram estes procedimentos que mais influenciaram a temperatura do motor. De notar que a análise foi feita apenas considerando uma fase do motor com os parâmetro referidos, para comprovar a eficácia do algoritmo de redes neurais perante situações inesperadas e irregulares.

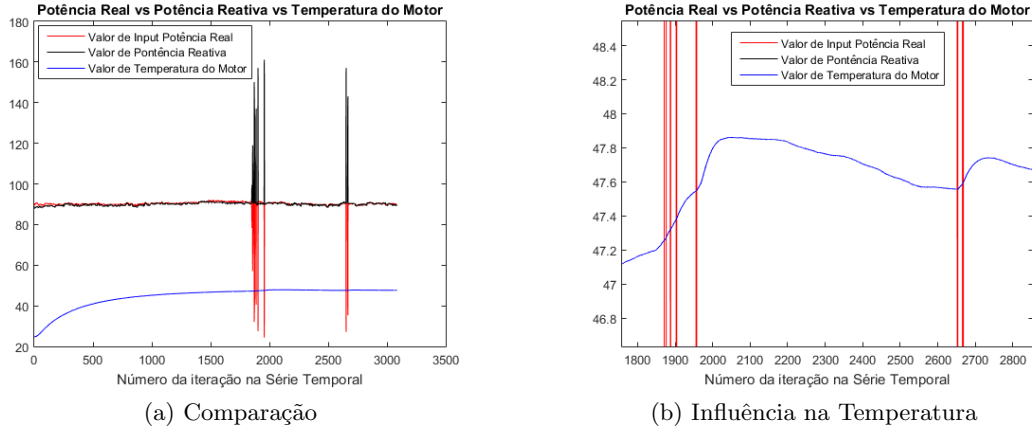


Figura 5.5: Relação entre alguns parâmetros externos na temperatura do motor para o caso de estudo 2 (Potência reativa [Kva], Potência ativa [w], Temperatura do motor [$^{\circ}\text{C}$]).

5.1.2 Método NARX

As redes não lineares autorregressivas com variáveis exógenas de entrada (NARX) é um método que "aprende" a prever as iterações subsequentes de uma série temporal (parâmetros de saída, neste caso concreto a temperatura do motor), não só a partir do comportamento das iterações anteriores, mas também a partir de séries com o registo dos parâmetros externos (parâmetros de entrada, que neste caso serão a voltagem, a potência, a temperatura ambiente, a corrente e o fator de potência medidos na fase 1 da alimentação do motor). Estas propriedades elétricas e a temperatura ambiente foram os métodos de análise escolhidos que maior interferência causaram na variação dessa temperatura.

O código em *Matlab* começa pelo tratamento dos dados, a sua normalização e retirada de caracteres nulos ou inválidos. Em seguida, o processo de treino, a função de ativação a função sigmóide em vez da tangente hiperbólica, o que tornando o processo total da simulação até 4 vezes mais rápido, no entanto, isto não significa que a etapa de treino também o seja, já que o tempo de treino varia sempre, até perante o mesmo problema, consequentemente as simulações obtêm soluções diferentes. Além disso o algoritmo de treino utilizado foi o de Levenberg-Marquardt.

Sabendo-se que a rede neuronal tem 15 camadas escondidas e que os aspetos externos não influenciam no imediato a temperatura do motor, escolheu-se a razão de 1/5 no atraso entre saídas e entradas na rede neuronal ou seja, para cada valor de *output* registado associou-se os *inputs* que aconteceram nas 5 iterações anteriores. Deste modo, com os parâmetros e o procedimento definidos, procede-se ao treino da rede, no entanto cada treino teve a sua *performance* e demonstrou resultados melhores ou piores, de forma aleatória. Para contornar esta situação e escolher a melhor *performance* de treino, treinou-se a rede, restringindo o erro de treino, isto é, a diferença entre valores alvo e de saída da rede. Quando esta diferença for

inferior a um valor suficientemente baixo o algoritmo avança.

Findo o processo de treino, simularam-se as previsões um passo à frente, utilizando a rede aberta, enquanto que para previsões multi-passo, a rede tem de ter ciclo fechado, em que substitui a alimentação da rede com as entradas em conexão direta a partir da camada de saída.

Neste método foram abordadas duas configurações, numa apenas foi utilizado um parâmetro de entrada e na outra foram considerando todos os parâmetros externos.

5.1.2.1 Previsão de uma Iteração

Nesta subsecção são apresentados os resultados da previsão um passo à frente com uma análise individual e comparativa dos dois casos de estudo apresentados.

A previsão um passo à frente, e considerando apenas um parâmetro de entrada, a temperatura ambiente no caso 1 e o fator de potência no caso 2, foi feita à medida que a série avançava para se poder comparar os valores registados pelo sensor (a azul) e os valores previstos a partir da simulação com a rede neuronal (a vermelho).

No primeiro caso, a figura 5.6a apresenta o resultado da previsão um passo à frente que denota um bom desempenho. Se se comparar com o caso de estudo 2 (figura 5.6b), os resultados apresentavam, inicialmente, um desempenho superior, mas a partir da iteração 1900, verificou-se um aumento significativo do erro de previsão, isto devido às cargas aplicadas no motor que provocaram alterações nas variáveis de entrada e influenciaram a previsão. Concluiu-se que a rede não estava totalmente preparada para esta situação, porém, na segunda carga (perto da iteração 2700), a rede "aprendeu" e melhorou a sua eficiência e a estabilização dos resultados foi mais rápida.

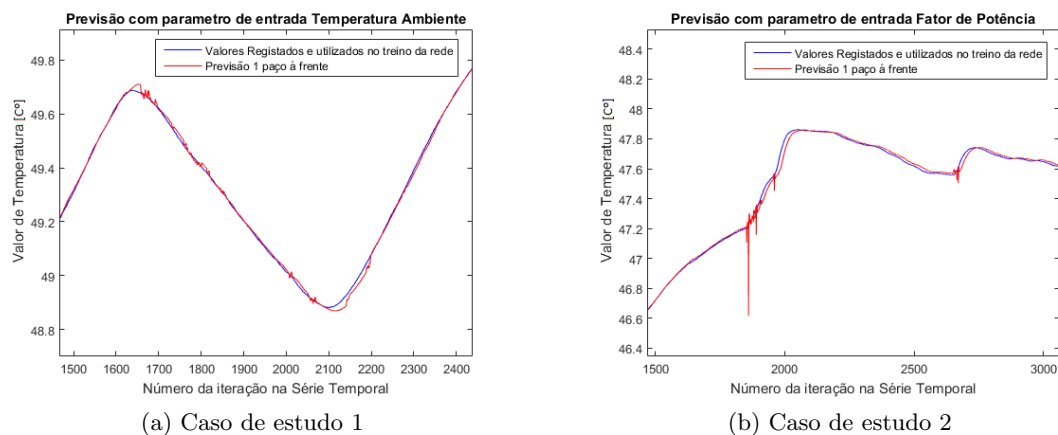


Figura 5.6: Previsão de uma iteração com o parâmetro externo manipulado.

Este resultado é de facto interessante, pois é a resposta da rede perante irregularidades

para as quais não tinha, até então, sido treinada, situação que ocorreria numa possível falha.

Utilizando uma nova abordagem para as mesmas séries, foi feita uma nova simulação, mas agora tendo em consideração todos os parâmetros de entrada, cujos resultados estão apresentados na figura 5.7. Nos dois casos de estudo, a simulação melhorou mesmo para o estudo 2, que tinha apresentado valores piores aquando da aplicação da carga, que provou a eficácia da aprendizagem.

Após esta análise, comprovou-se que o processo de treino é uma etapa complexa, mas determinante para uma boa previsão, além a previsão melhora, quando se aumentam o número de parâmetros de entrada.

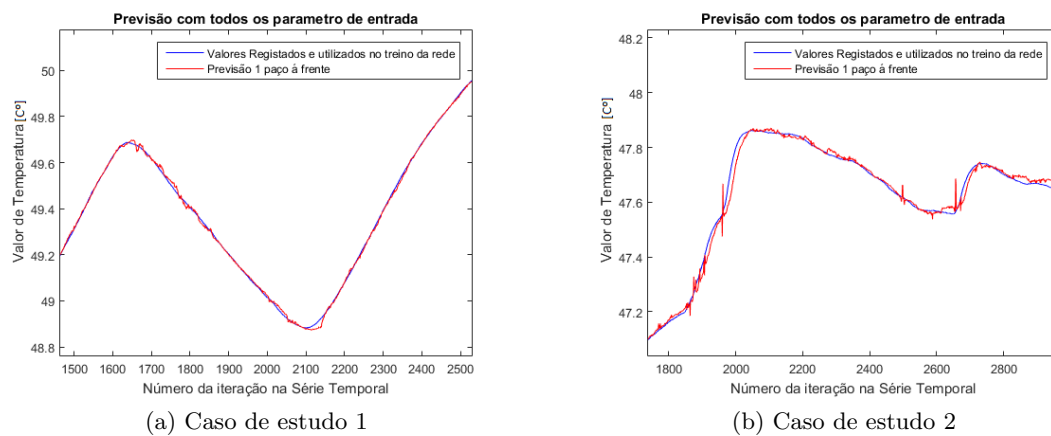


Figura 5.7: Previsão de uma iteração com todos os parâmetros de entrada.

5.1.2.2 Previsão de várias iterações

Para verificar a eficácia da previsão das várias iterações seguintes à série, durante o treino da rede, decidiu-se ignorar as últimas 30 iterações registadas, tanto para a série dos valores de entrada como para os valores de saída. Assim, com esses valores, é possível simular-se e confrontar-se os resultados da previsão com os valores esperados, de forma idêntica à análise anterior.

Na figura 5.8 são apresentados os resultados para os dois casos de estudo: a verde, os valores reais, utilizando apenas os parâmetros externos relevantes em cada caso, a temperatura ambiente e o fator de potência, respetivamente; a amarelo, os valores previstos pela rede; a vermelho, a previsão um passo à frente. Focando agora a análise multi-passo, o cenário é oposto ao anterior, apresentando o caso de estudo 1 e 2 melhores resultados em termos de desvio relativamente aos reais, uma vez que apresenta poucas variações acentuadas nos resultados.

Em seguida, simulou-se a previsão de várias iterações, considerando todos os parâmetros de entrada, como se observa na figura 5.9. Os resultados melhoraram significativamente no

caso de estudo 1, com a previsão acertada de alguns valores. Um comportamento idêntico verificou-se no caso de estudo 2. Mais uma vez se confirmou que quanto maior for o número de parâmetros externos a considerar melhores serão as previsões.

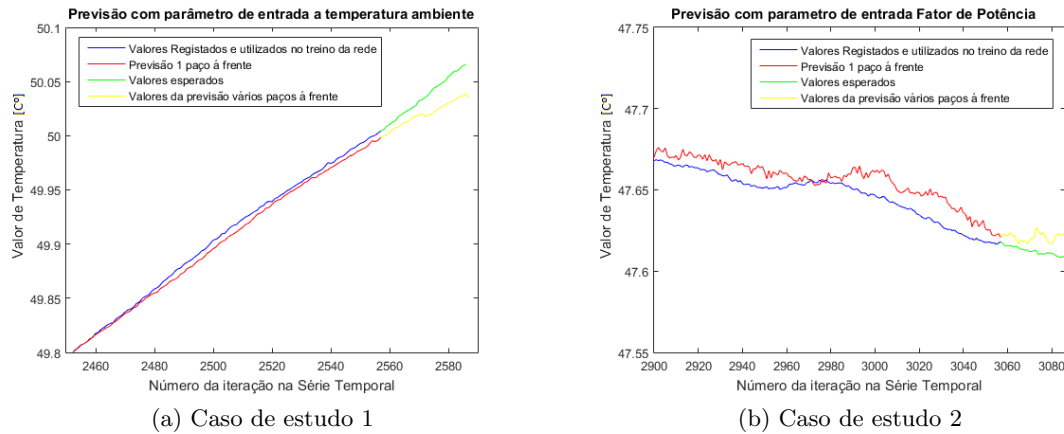


Figura 5.8: Previsão de vários passos à frente e com o parâmetro de entrada manipulado.




Figura 5.9: Previsão de vários passos à frente e com várias entradas.

Em suma, esta análise mostrou que este método de previsão é eficiente, dado que apresenta uma maior exatidão, quando considerados todos os parâmetros externos. Acrescenta-se que, obviamente, quanto mais distante for a iteração a prever, pior se torna o resultado.

5.1.3 Método NAR

Este método utiliza redes não lineares autorregressivas da mesma forma que o método anterior, no entanto, difere pelo facto de não recorrer a variáveis exógenas de entrada, ou seja, prevê as iterações a partir do comportamento seu anterior registado na série temporal,

neste caso é temperatura do motor.

O processo de treino foi o mesmo utilizado anteriormente, a saber o de *Lvenberg-Marquardt*, que recorre à função de ativação sigmóide e a 15 camadas escondidas.

5.1.3.1 Previsão de uma iteração

Esta configuração da rede, neste contexto, é a que melhores resultados apresenta, como podemos se pode observar na figura 5.10. São resultados satisfatórios que permitem concluir que a previsão é mais eficiente sem a utilização de parâmetros externos de entrada, verificando apenas erros na ordem das milésimas.

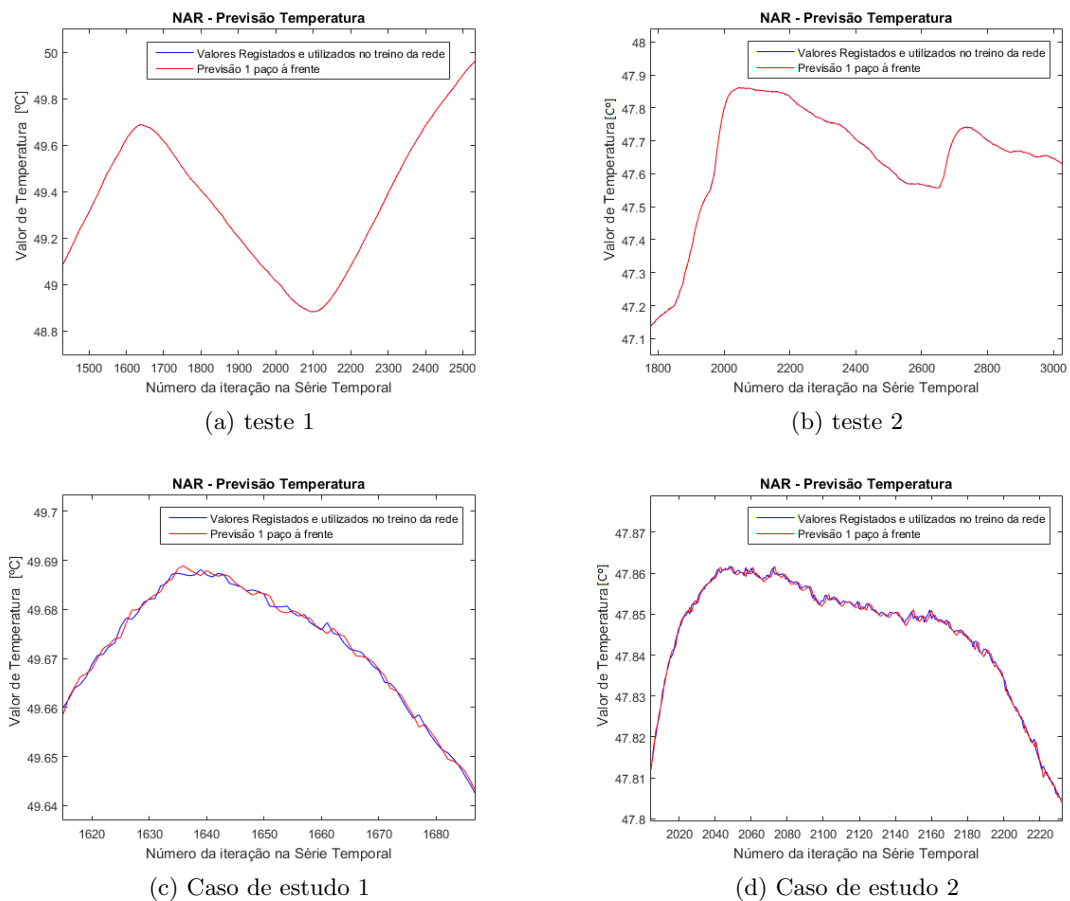


Figura 5.10: Previsão de uma iteração à frente.

Apesar destes resultados apresentarem um bom desempenho, isto não significa que seja o método mais eficiente, porque os parâmetros externos de entrada afetam a temperatura do motor e, omitindo esse valores, a previsão torna-se complexa, no entanto, para estas amostras, a influência dos parâmetros externos não alterou de forma muito significativa a temperatura

do motor o que contribuindo para um erro menor. Ao considerar apenas a temperatura do motor, comprova-se que o seu comportamento é estável, sem alterações bruscas. Estas podem ser algumas das causas que contribuíram para um melhor resultado.

5.1.3.2 Previsão Multi-Iteração

A análise dos resultados da previsão de multi-iterações foi feita da mesma forma que foi utilizada no método NARX. A partir de uma série de amostras de temperatura, retiraram-se as últimas 50 iterações para verificar a sua eficácia.

Com os gráficos apresentados na figura 5.11, constata-se que, apesar da previsão de um paço à frente ter sido bastante eficiente, o mesmo não acontece com a previsão de várias iterações. O erro aumenta significativamente à medida que a previsão se distancia. No caso de estudo 2, os resultados foram pouco satisfatórios, uma vez que não acertando em nenhuma iteração, no entanto, no caso 1, as previsões melhoraram, principalmente nas primeiras iterações.

Posto isto, a previsão multi-iteração tem um aumento do erro superior, quando comparada com o mesmo tipo de previsão que o método NARX, para as previsões mais distantes.

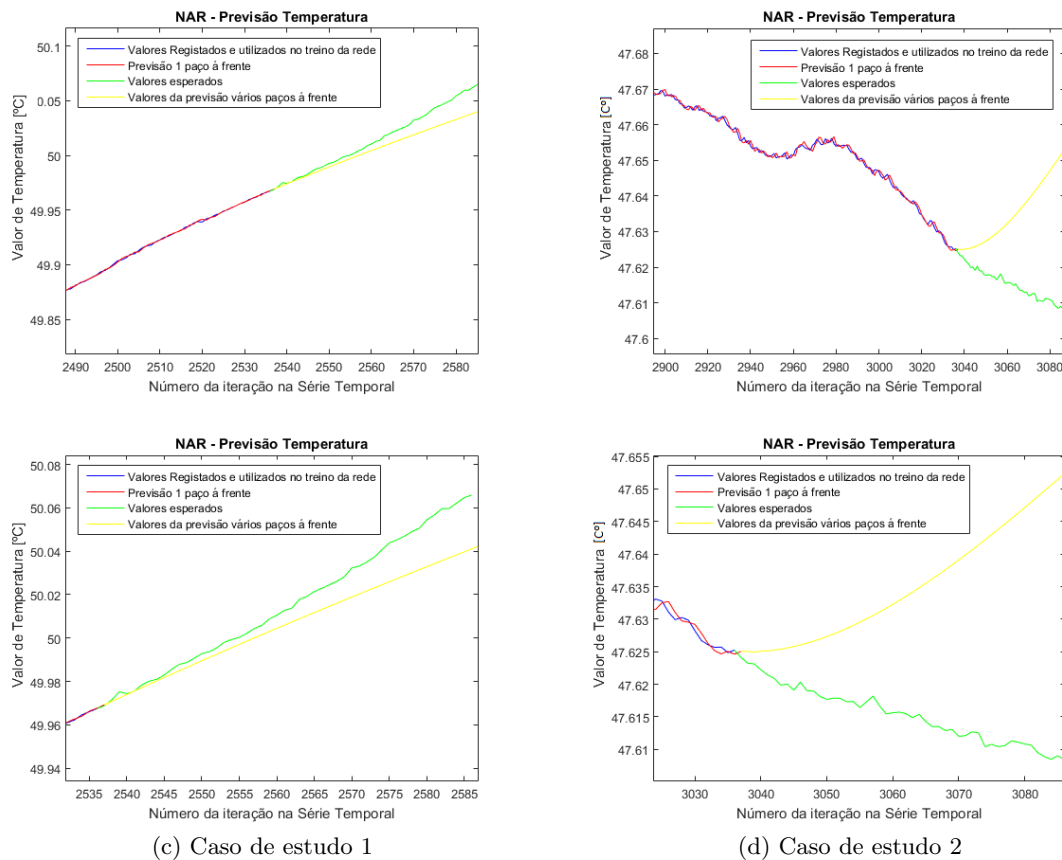


Figura 5.11: Previsão Multi-Iterações.

5.1.4 Tempo de processamento

O tempo é muito importante, principalmente, quando se fala de aplicações que processam em tempo real.

Neste subcapítulo, compararam-se tempos de processamento testados num computador com processador Intel I3 de 2,4 GHz de velocidade de processamento.

Os resultados apresentados na tabela 5.12 mostram que, para cada método, fazendo variar o número de amostras da série temporal, primeiro com 150 iterações, depois com 2356 dá-se um aumento significativo do tempo de processamento. Trata-se de facto de um processo demorado quando se fala de aplicações para processar em tempo real.

O método NARX, com um parâmetro entrada, foi o que apresentou melhor tempo quando se está perante séries com grande número de amostras e o método NAR foi o que apresentou o melhor tempo, 3,8 segundos, para séries de pequena dimensão.




Figura 5.12: Tempo total de processamento para todos os métodos com número de iterações diferente.

Com o intuito de localizar a fonte destes elevados tempos de processamento, e com um diagnóstico pré-concebido, decidiu-se comparar o tempo de treino com o tempo total de processamento, chegando-se aos valores apresentados na figura 5.13. São valores interessantes, na medida em que existem casos que atingiram 94,81% (ver apêndice A.4) do tempo total de processamento, confirmando assim que o treino da rede é a fase que mais processamento exige.




Figura 5.13: Relação tempo de simulação com tempo de treino.

Face a estes resultados, verifica-se que à medida que o número de amostras aumenta, o tempo de processamento aumenta de forma significativa, sendo o processo de treino o principal causador desta demora.

Para reduzir este tempo numa aplicação em tempo real, a utilização do algoritmo, com uma rede neuronal já treinada, melhoraria significativamente este resultados, daí a criação de uma aplicação com rede treinada na solução apresentada nesta dissertação. Porém as previsões não serão tão fiáveis, visto que o comportamento da temperatura do motor varia sempre ao longo da sua vida útil e o treino anteriormente feito tornar-se-á desatualizado, a não ser que sejam realizados treinos da rede periodicamente, em vez de se treinar aquando de uma previsão.

Além do tempo de processamento da etapa de treino, o número de amostras também o influencia expressivamente, assim para contornar este efeito, as séries temporais podem ser tratadas de forma eficiente reduzindo o número de iterações, através de processos de *data mining*.

5.2 Conclusões e propostas de trabalho futuro

Neste documento, foi desenvolvida e proposta uma solução para apoio à manutenção preditiva integrada num *software* SCADA, garantindo assim o cumprimento dos objetivos inicialmente propostos. Além disso, foi também estudada a eficácia de várias formas de previsões, apoiadas pelo algoritmo de redes neuronais artificiais e avaliados tempos de processamento e *performance*.

Começou-se por investigar, em toda a literatura existente, a manutenção em geral, com ênfase na preditiva e no estudo de métodos preditivos, definindo-se como principal destaque o

uso de redes neuronais para previsão de séries temporais. Trata-se de um método eficaz, bastante utilizado, tanto em análises financeiras como nas ciências biomédicas. Existem inúmeros estudos, nomeadamente no domínio do diagnóstico médico que incentivam a sua aplicação não apenas em seres vivos mas em equipamentos industriais.

Trançado assim o caminho, passou-se à seleção dos equipamentos disponíveis que mais se adequassem à análise da evolução da temperatura de um motor elétrico, para antecipar sobreaquecimentos.

Após a seleção, montagem e configuração dos equipamentos desenvolveu-se *software*, nomeadamente uma aplicação em *software SCADA*, aliada a uma aplicação desenvolvida em linguagem *Matlab*, que garantisse um apoio importante aos órgãos superiores de gestão, na aplicação e gestão da manutenção preditiva.

Verificou-se que foi possível incorporar ferramentas preditivas nos *software SCADA*, não sendo necessário alterar as plataformas existentes numa empresa, o que facilitaria a mudança do método de manutenção. Acrescenta-se que, mais uma vez, se provou que as redes neuronais são algoritmos eficazes para a prevenção de acontecimentos com várias ferramentas que facilitam o seu desenvolvimento e aplicação. O fator que limita a aplicação é a fase de treino da rede; trata-se de um processo complexo, que inviabiliza as previsões, em algumas situações.

O método proposto nesta dissertação encontra-se em estado funcional, como era pretendido, no entanto há situações que podem ser melhoradas.

Assim como trabalhos futuros propõe-se:

- Ampliar este sistema num ambiente em escala maior, ou seja, aumentar do número e tipo do equipamentos a monitorizar, o que faria incrementar a quantidade de dados a analisar e consequentemente alargaria a quantidade de processamento.
- Utilizar câmaras termográficas para a análise térmica, uma vez que permitem mapear as regiões com temperaturas mais elevadas, facultando assim uma avaliação mais global de todo o motor.
- Analisar as vibrações do motor a partir de sensores específicos, devidamente isolados de interferências e ruído.
- Estudar e aplicar novas abordagens na análise de desempenho dos equipamentos.
- Utilização de motores mais potentes com recurso a transformadores de corrente e analisar o seu desempenho.
- Estudar e otimizar o processo de treino de redes neuronais, uma vez que foi a situação que maiores dificuldades causou no desenvolvimento deste trabalho; os algoritmos genéticos são um exemplo que pode ser utilizado nesse sentido.

Bibliografia

- [1] J. Moubray, “Reliability centered maintenance”, 2ª ed., vol. 1, Great Britain: Industrial Press Inc., 1997.
- [2] F. I. Khan e M. M. Haddara, “Risk-based maintenance (RBM): A quantitative approach for maintenance/inspection scheduling and planning”, *Journal of Loss Prevention in the Process Industries*, vol. 16, no. 6, pp. 561–573, 2003.
- [3] M. Almeida. (2016, Abril), “Manutenção preditiva : benefícios e lucratividade .” Itajubá, pp. 1–5, 2012. [Em Linha]. Disponível em: <http://www.mtaev.com.br/download/mnt2.pdf>
- [4] R. Dunn, “Advanced maintenance technologies.” *Plant Engineering*, vol. 41, no. 12, pp.80-93, 1987.
- [5] R. Mobley, *An introduction to predictive maintenance*, 2ª Ed. Butterworth-Heinemann, Elsevier Science, 2002.
- [6] L. Hans, “Management of Industrial Maintenance - Economic evaluation of maintenance Policies”, *International Journal of Operations & Production Management*, pp. 716–736, 1999.
- [7] K. Nikolopoulos, K. Metaxiotis, N. Lekatis e V. Assimakopoulos, “Integrating industrial maintenance strategy into ERP”, *Industrial Management & Data Systems*, vol. 103, no. 3, pp. 184–191, 2003. [Em Linha]. Disponível em: <http://eprints.lancs.ac.uk/29040/>
- [8] S. Takata, F. Kimura, F. J. A. M. V. Houten e E. Westkämper, “Maintenance : Changing Role in Life Cycle Management”, *CIRP Annals - Manufacturing Technology*, vol. 53, no. 2, pp. 643–655, 2004.
- [9] E. Seixas, “Manutenção Centrada na Confiabilidade Estabelecendo a Política de Manutenção com Base nos Mecanismos de Falha dos Equipamentos”, *Reliasoft Brasil*, 2006.
- [10] A. Jovanovic, “Risk-based inspection and maintenance in power and process plants in Europe”, *Nuclear Engineering and Design*, vol. 226, no. 2, pp. 165–182, 2003.

-
- [11] J. D. Campbell, "Outsourcing in maintenance management - A valid alternative to self-provision", *Journal of Quality in Maintenance Engineering*, vol. 1, pp. 18–24, 1995.
- [12] A. Al-hammad, S. Assaf e M. Al-shihah, "Ranking of barriers for effective maintenance by using TOPSIS approach Rajesh", *Journal of Quality in Maintenance Engineering*, vol. 3, no. 1997, pp. 29–39, 2009.
- [13] T. A. Nogueira, "Redes de comunicação para sistemas de automação industrial", Dissertação de Mestrado, 2009.
- [14] A. C. Márquez, *The maintenance management framework: models and methods for complex systems maintenace*, S. S. & B. Media, Ed., 2007.
- [15] N. Moro e A. Auras, "Introdução a Gestão de Manutenção", Centro Federal de Educação Tecnológica de Santa Catarina, Florianópolis, Tech. Rep., 2007.
- [16] J. S. Cabral, *Organização e gestão da manutenção: dos conceitos à prática.*, 5^a ed. Lisboa: Lidel, 2006.
- [17] M. V. Brown. (Abril, 2016), "Applying the Predictive Approach", New Standard Institute, Inc., 2003. [Em Linha]. Disponível em: http://www.plantservices.com/assets/knowledge_centers/ansi/assets/Applying_the_Predictive_Approach.pdf
- [18] J. Salles e L. Walter. (Junho, 2016), "Manutenção Preditiva : Caminho para a Excelência e Vantagem Competitiva", Universidade Metodista de Piracicaba, Piracicaba, Tech. Rep., 2006. [Em Linha]. Disponível em: <http://www.unimep.br/phpg/mostraacademica/anais/4mostra/pdfs/616.pdf>
- [19] H. De Faria, J. G. S. Costa e J. L. M. Olivas, "A review of monitoring methods for predictive maintenance of electric power transformers based on dissolved gas analysis", *Renewable e Sustainable Energy Reviews*, vol. 46, pp. 201–209, 2015. [Em Linha]. Disponível em: <http://dx.doi.org/10.1016/j.rser.2015.02.052>
- [20] F. M. C. Santos, "Manutenção Preditiva e Pró-Activa. Filosofias Alternativas ou Complementares. Estudo de Caso", Dissertação de Mestrado, Instituto Superior de Engenharia de Lisboa, 2013.
- [21] Scheffer, Cornelius e P. Girdhar, *Practical Machinery Vibration Analysis e Predictive Maintenance*, 1^a Ed. Great Britain: Elsevier, 2004.
- [22] WEG. (Março, 2016), "Motores Elétricos - Guia de Especificação", 2014. [Em Linha]. Disponível em: <http://ecatalog.weg.net/files/wegnet/WEG-guia-de-especificacao-de-motores-eletricos-50032749-manual-portugues-br.pdf>

- [23] Eletric Power Research Institute, “Electric Motor Predictive and Preventive”, Tech. Rep., 1992.
- [24] H.-H. Hsieh, B.-H. Lee, H.-K. Wu e H.-C. Chien, “Study on using design patterns to implement a simulation system for WiMAX network”, *EURASIP Journal on Wireless Communications and Networking*, vol. 2016, no. 1, p. 143, 2016. [Em Linha]. Disponível em: <http://jwcn.eurasipjournals.springeropen.com/articles/10.1186/s13638-016-0639-8>
- [25] J. J. McClellan, “The benefit of using simulation to improve the implementation of lean manufacturing case study: quick changeovers to allow level loading of the assembly line”, Dissertação de Mestrado, Brigham Young University, 2004.
- [26] D. Bansal, D. J. Evans e B. Jones, “A real-time predictive maintenance system for machine systems”, *International Journal of Machine Tools and Manufacture*, vol. 44, no. 7-8, pp. 759–766, jun 2004. [Em Linha]. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0890695504000392>
- [27] D. M. Soares, “Utilização de serviços web para o controlo integrado de produção”, Dissertação de Mestrado, Universidade de Aveiro, 2011.
- [28] Progea. (Março, 2016), “Movicon 11 User Guide”, 2009. [Em Linha]. Disponível em: http://www.rem-technik.cz/files/fck_userfiles/file/VIPA/MOVICON/Man_Eng_Mov11_3_Users%20Guide.pdf
- [29] National Instruments. (Março, 2016), “Lookout Developer’s Manual”, 2003. [Em Linha]. Disponível em: <http://www.ni.com/pdf/manuals/322390d.pdf>
- [30] S. Chapman, “Proceedings of the 55th Annual Meeting of the American Power Conference on Computerisation of Maintenance Management Systems”, 1993.
- [31] O. Duran, “Computer-aided maintenance management systems selection based on a fuzzy AHP approach”, *Advances in Engineering Software*, vol. 42, no. 10, pp. 821–829, 2011.
- [32] T. Rintamäki, A. Kanto, H. Kuusela e M. T. Spence, “AHP-based evaluation of CMMS software”, *International Journal of Retail and Distribution Management*, vol. 34, no. 1, pp. 6–24, 2006.
- [33] A. P. Almeida, “Preparação de um Plano de Manutenção”, 2001. [Em Linha]. Disponível em: http://www.plantservices.com/assets/knowledge_centers/ni/assets/Applying_the_Predictive_Approach.pdf
- [34] R. A. Barbosa, F. N. da Costa, L. M. L. Ferreira, C. E. d. C. B. Nunes, and I. B. S. Alves, “Elaboração E Implementação De Um Plano De Manutenção Com Auxílio Do 5S: Metodologia Aplicada de uma Microempresa”, *Enegepe*, 2009.

- [35] F. E. Harrell, "Regression Modeling Strategies", 1^a ed. Nashville: Springer 2001. [Em Linha]. Disponível em: <http://link.springer.com/10.1007/978-1-4757-3462-1>
- [36] F. Nogueira. (Abril, 2016), "Modelagem e Simulação - Modelos de Previsão", 2010. [Em Linha]. Disponível em: <http://www.ufjf.br/epd042/files/2009/02/previsao1.pdf>
- [37] H. Migon, "Análise de Séries Temporais", Universidade Federal do Rio de Janeiro, Tech. Rep., 2007.
- [38] G. E. P. Box, G. M. Jenkins, G. C. Reinsel e G. M. I. Jung, "Time series analysis: forecasting and control", 5^a ed. New Jersey: John Wiley and Sons, Inc., 2015.
- [39] M. Barros. (Abril, 2016), "Introdução às Séries Temporais e aos Modelos ARIMA", pp. 202–229, 2004. [Em Linha]. Disponível em: http://www.mbarros.com/documentos/upload/Livro.Processos_Cap_5.parte.pdf
- [40] V. Miranda, "Previsão de cargas por séries temporais", Departamento de Engenharia Electrotécnica e de Computadores Faculdade de Engenharia da Universidade do Porto, Tech. Rep., 2002.
- [41] V. Naquela e P. D. P. Pires, "Modelos de Previsão: Uma Revisão de Literatua", Dissertação de Mestrado, Universidade Portucalense - Departamento de Finanças, 2014.
- [42] M. Mitchell. (Julho, 2016), "An introduction to genetic algorithms" 5^aed. Massachusetts - A Bradford Book The MIT Press, 1998. [Livro electrónico]. Disponível em: <http://www.boente.eti.br/fuzzy/ebook-fuzzy-mitchell.pdf>
- [43] D. K. Mohanta, P. K. Sadhu e R. Chakrabarti, "Deterministic and stochastic approach for safety and reliability optimization of captive power plant maintenance scheduling using GA/SA-based hybrid techniques: A comparison of results." *Reliability Engineering & System Safety*, vol. 92, no. 2, pp. 187–199, 2007. [Em Linha]. Disponível em: <http://linkinghub.elsevier.com/retrieve/pii/S0951832005002711>
- [44] C. M. N. A. Pereira, C. M. F. Lapa, A. C. A. Mol e A. F. Da Luz, "A Particle Swarm Optimization (PSO) approach for non-periodic preventive maintenance scheduling programming", *Progress in Nuclear Energy*, vol. 52, no. 8, pp. 710–714, 2010. [Em Linha]. Disponível em: <http://dx.doi.org/10.1016/j.pnucene.2010.04.009>
- [45] Y.-T. Tsai, K.-S. Wang e H.-Y. Teng, "Optimizing preventive maintenance for mechanical components using genetic algorithms", *Reliability Engineering & System Safety*, vol. 74, no. 1, pp. 89–97, 2001. [Em Linha]. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0951832001000655>

- [46] A. Freitas. (Julho, 2016), “Árvores de Decisão”, 2016. [Em Linha]. Disponível em: <http://web.tecnico.ulisboa.pt/ana.freitas/bioinformatics.ath.cx/bioinformatics.ath.cx/indexf23d.html?id=199>
- [47] J. Gama. (Julho, 2016), “Árvores de Decisão Sumario Árvores de Decisão”, 2002. [Em Linha]. Disponível em: https://www.dcc.fc.up.pt/~ines/aulas/MIM/arvores_de_decisao.pdf
- [48] C. Brito. (Março, 2016), “Redes Neurais Artificiais”, 2000. [Em Linha]. Disponível em: www.deei.fct.ualg.pt/~a25074/.../RedesNeuraisArtificiais.pps
- [49] D. Bansal, D. J. Evans e B. Jones, “Application of a real-time predictive maintenance system to a production machine system”, *International Journal of Machine Tools and Manufacture*, vol. 45, no. 10, pp. 1210–1221, aug 2005. [Em Linha]. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0890695504003177>
- [50] D. Bansal, D. Evans e B. Jones, “BJEST: A reverse algorithm for the real-time predictive maintenance system”, *International Journal of Machine Tools and Manufacture*, vol. 46, no. 10, pp. 1068–1078, aug 2006. [Em Linha]. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0890695505002208>
- [51] M. Carnero, “Selection of diagnostic techniques and instrumentation in a predictive maintenance program. A case study”, *Decision Support Systems*, vol. 38, no. 4, pp. 539–555, jan 2005. [Em Linha]. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0167923603001283>
- [52] S. Crone. (Abril, 2016), “Tutorial on Forecasting with Artificial Neural Networks”, 2005. [Em Linha]. Disponível em: http://www.neural-forecasting.com/Downloads/EVIC05_tutorial/EVIC'05Slides-ForecastingwithNeuralNetworksTutorialSFCrone.pdf
- [53] J. M. N. Silva, “Redes Neurais Artificiais : Rede Hopfield e Redes Estocásticas”, Universidade Federal Fluminense, Tech. Rep., 2003.
- [54] D. Kriesel. (Abril, 2016), *A Brief Introduction to Neural Networks*, 2005. [Livro eletrônico]. Disponível em: <http://www.dkriesel.com>
- [55] L. G. L. Fernandes, “Utilizacao de Redes Neurais na Analise e Previsdo de Series Temporais”, Dissertação de Mestrado, Universidade Federal do Rio Grande do Sul, 1995.
- [56] A. Rocha, “Aprendizagem Automática : Redes Neurais Redes Neurais Redes Neurais”, pp. 1–15, 2006.
- [57] T. N. M. Machado, “Modelação de Séries Temporais – Métodos Lineares e Não Lineares”, Dissertação de Mestrado, Instituto Politécnico de Bragança, 2009.

-
- [58] Texas Instruments, “LM35 Precision Centigrade Temperature Sensors Precision Centigrade Temperature Sensors”, 2016.
- [59] Danfoss. (Julho, 2016), “Data sheet Temperature sensors (Pt 1000)”, pp. 10–13, 2005. [Em Linha]. Disponível em: http://heating.danfoss.com/PCMPDF/VD74I802_Pt1000.pdf
- [60] Janitza electronic GmbH, “Janitza Umg 604 Datasheet”, 2011. [Em Linha]. Disponível em: <http://www.janitza.com/products/energy-measurement/umg-604/>
- [61] VIPA GmbH, “VIPA System SLIO CPU — 015-CEFPR00 — Manual”, Alemanha, 2009.

Apêndice A

Apêndice

A.1 Outros equipamentos de análise para manutenção

A análise de óleos é mais uma forma de análise para a manutenção, já que a partir desta análise é possível economizar lubrificantes, identificando o momento adequado à sua mudança ou renovação. Os resíduos presentes ou a constante necessidade de lubrificante podem também ser uma predição do mau funcionamento do equipamento. Na figura A.1, observa-se um exemplo do equipamento utilizado na análise dos óleos, que permite medir a condutividade, a resistividade e as perdas. Com estas propriedades identificadas, conhece-se o estado em que se encontra o líquido refrigerante.



Figura A.1: Analisador de óleo da SKF.

A análise estroboscópica é também uma outra forma de monitorização e consiste na utilização de um estroboscópio (figura A.2). Trata-se de um dispositivo ótico que permite o estudo e registo do movimento contínuo ou periódico de um equipamento a altas velocidades de rotação. Tem como objetivo, por exemplo, a verificação do estado das pás em ventiladores, acoplamentos, rodas dentadas, eixos-árvore de máquinas/ferramentas, entre outros. Com este utensílio obtêm-se imagens discretas representativas do percurso que o corpo descreve. Este efeito é conseguido através da oscilação entre a iluminação com uma luz intensa e o

bloqueamento dessa luz com o diafragma - lâmpada estroboscópia ¹.



Figura A.2: Estroboscópio TKRS10 da SKF.

A.2 Alimentação do autômato

Para a utilização do autômato é necessitamos ligá-lo a um conversor de 220v AC para 24v AC que é a tensão de alimentação indicada.

Como podemos ver na figura A.3, existe uma entrada a 220v AC e uma saída a 24v DC em que o positivo será ligado ao pino 6 do *slot* 1 do *rack*, que é o módulo de alimentação (figura A.4), que será ligado em série com o pino 4. Relativamente ao negativo, este irá ligar no 7 em série com o 8.




Figura A.3: Conversor utilizado.

Pos.	Function	Type	Description
1	---	---	not connected
2	DC 24V	I	DC 24V for power section supply
3	0V	I	GND for power section supply
4	Sys DC 24V	I	DC 24V for electronic section supply
5	---	---	not connected
6	DC 24V	I	DC 24V for power section supply
7	0V	I	GND for power section supply
8	Sys 0V	I	GND for electronic section supply

I Input

Figura A.4: Modulo de alimentação do autômato slio [61]

¹consultado a 12-06-2016, manual do equipamento TKRS10 da SKF em <http://www.skf.com/binary/149-32013/11301PTBRstroboscopes.pdf>

A.3 Programação Ladder Autômato

Na secção "OB1", ao observar a figura A.5, percebem-se as funções principais criadas. A primeira "network 5" é responsável por mover o valor registado da entrada analógica do autômato (PIW272), para uma memória *word* (MW100). A segunda *network* é a chamada da função previamente criada (FC1) que contém como parâmetros de entrada, a memória *word* (MW100), as constantes Y1 e Y0 que correspondem ao intervalo de valores para o qual a variável de saída (MD2) está restringida. De forma idêntica X1 e X0 apresentam o intervalo de valores no qual está compreendido o parâmetro de entrada (MW100). Esta função tem como objetivo escalar os valores registados pela entrada analógica, uma vez que se trata de um sensor linear, sendo assim possível obter a temperatura em graus celsius na variável "double" (MD2).

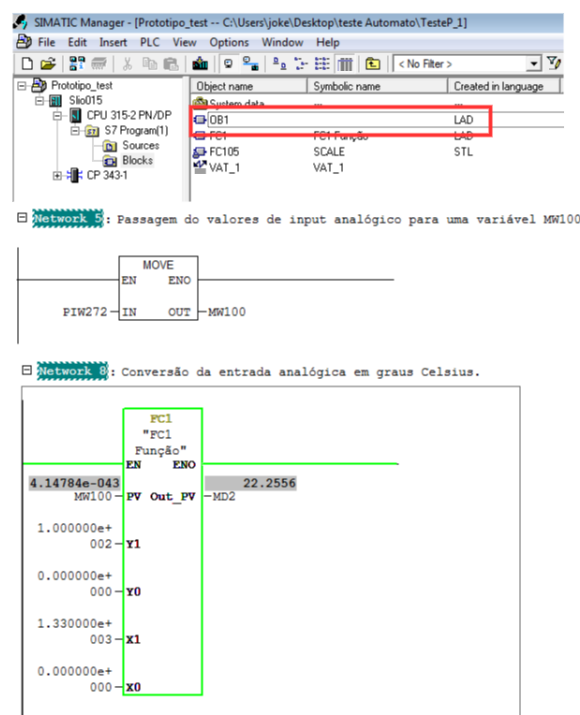


Figura A.5: Parte do OB1.

Para permitir a ativação das saídas do PLC a partir do *Movicon*, este processo realizou-se com o auxílio de uma memória bit (por exemplo M1.0), conforme é apresentado na figura A.6. Esta memória bit, no *Movicon*, está associada a um *switch*, pelo qual o utilizador poderá realizar a ativação/desativação da saída associada.

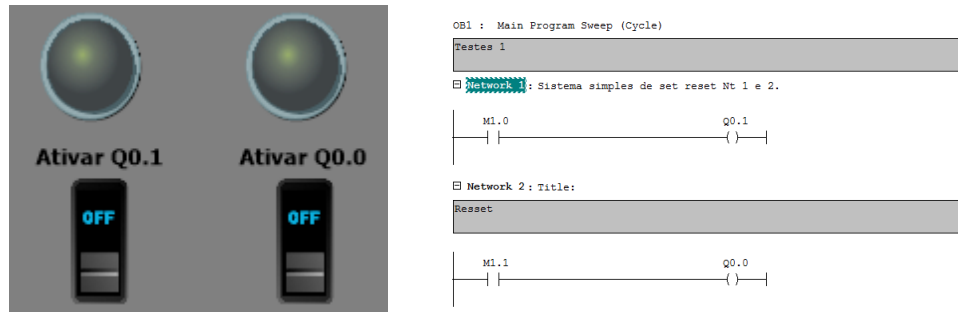


Figura A.6: Ativação de saídas a partir do *Movicon*.

A.4 Tempos de Processamento

Tabela A.1: Tempos totais de processamento variando o número de amostras e o tipo.

Nº de Amostras	150	2356
NARX 1 Input[s]	17,836	25,040
NARX Multi-Input[s]	18,100	39,898
NAR[s]	3,800	52,577

Tabela A.2: Tempo de processamento no treino da rede.

Nº de Amostras	150	2356
NARX 1 Input[s]	8,127	22,959
NARX Multi-Input[s]	14,470	37,828
NAR[s]	3,560	49,227

Tabela A.3: Relação do tempo de processamento treino/total.

Nº de Amostras	150	2356
NARX 1 Input[s]	45,57 %	91,69 %
NARX Multi-Input[s]	79,94 %	94,81 %
NAR[s]	93,68 %	93,63 %